# This Page Is Inserted by IFW Operations and is not a part of the Official Record

# **BEST AVAILABLE IMAGES**

Defective images within this document are accurate representations of the original documents submitted by the applicant.

Defects in the images may include (but are not limited to):

- BLACK BORDERS
- TEXT CUT OFF AT TOP, BOTTOM OR SIDES
- FADED TEXT
- ILLEGIBLE TEXT
- SKEWED/SLANTED IMAGES
- COLORED PHOTOS
- BLACK OR VERY BLACK AND WHITE DARK PHOTOS
- GRAY SCALE DOCUMENTS

# IMAGES ARE BEST AVAILABLE COPY.

As rescanning documents will not correct images, please do not report the images to the Image Problem Mailbox.

# **HIV-2** nucleotide sequences

Patent Number: EP0750041

**Publication** 

date:

1996-12-27

Inventor(s):

ALIZON MARC (FR); SONIGO PIERRE (FR); GUETARD DENISE (FR); MONTAGNIER

LUC (FR); TIOLLAIS PIERRE (FR); CHAKRABARTI LISA (FR); GUYADER MIREILLE

(FR); DESROSIERS RONALD (US); CLAVEL FRANCOISE (US)

Applicant(s)::

CENTRE NAT RECH SCIENT (FR); PASTEUR INSTITUT (FR)

Requested Patent:

☐ EP0750041, A3

Application

Number:

EP19960108720 19880115

Priority Number EP19880400084 19880115; FR19870001739 19870211; FR19870005398 19870415;

(s):

US19870003764 19870116

IPC

Classification: C12N15/49; C07K14/16; C12Q1/68

EC Classification:

C07K14/16B, C07K14/16D, C07K14/16, C12Q1/70B2B

Equivalents:

# **Abstract**

New peptides (I) have immunological properties in common with those of the peptide skeleton of the envelope protein of HIV-2 and also have a peptide structure in common with that of SIV (simian immunodeficiency virus)-7 glycoprotein. Also new are (i) a sequence of 9600 nucleotides corresponding to the SIV genome (reproduced in the specification, together with derived amino acid sequence of viral proteins gag, pol, env, Q, X, R, tat, art and F genes) and its fragments; (2) recombinant DNA contg. all or part of the CDNA from this sequence inserted into a vector, and (3) antigenic and immunogenic conjugates contg. (I).

Data supplied from the esp@cenet database - I2

Europäisches Patentamt European Patent Office Office européen des brevets



(11) EP 0 750 041 A2

(12)

# **DEMANDE DE BREVET EUROPEEN**

(43) Date de publication: 27.12.1996 Bulletin 1996/52 (51) Int CI.6: **C12N 15/49**, C07K 14/16, C12Q 1/68

(21) Numéro de dépôt: 96108720.2

(22) Date de dépôt: 15.01.1988

(84) Etats contractants désignés:
AT BE CH DE ES FR GB GR IT LI LU NL SE

(30) Priorité: 16.01.1987 US 3764 11.02.1987 FR 8701739 15.04.1987 FR 8705398

(62) Numéro de dépôt de la demande initiale en application de l'article 76 CBE: **88400084.5** 

(71) Demandeurs:

INSTITUT PASTEUR
 F-75015 Paris (FR)
 Etats contractants désignés:
 BE CH DE ES GB GR IT LI LU NL SE AT

 CENTRE NATIONAL DE LA RECHERCHE SCIENTIFIQUE 75007 Paris (FR)
Etats contractants désignés:

(72) Inventeurs:

 Alizon, Marc 75005 Paris (FR)

Montagnier, Luc
 92350 Le Plessis Robinson (FR)

 Guetard, Denise 75015 Paris (FR)

• Clavel, Françoise Rockville, MD 20852 (US)

 Sonigo, Pierre 75015 Paris (FR)

 Guyader, Mireille 75017 Paris (FR)

• Tiolials, Pierre 75013 Paris (FR)

Chakrabarti, Lisa
 750 Paris (FR)

 Desrosiers, Ronald Hudson, Massachusetts 01749 (US)

(74) Mandataire: Deselx, Anne Ernest Gutmann - Yves Plasseraud S.A. 3, rue Chauveau-Lagarde 75008 Paris (FR)

# Remarques:

Cette demande a été déposée le 31 - 05 - 1996 comme demande divisionnaire de la demande mentionnée sous le code INID 62.

# (54) Séquences de nucléotides de HIV-2

(57) L'invention concerne une séquence de nucléotides caractérisée en ce qu'elle répond à la séquence nucléotidique représentée à la figure 1B ou à la figure 1C, ou en ce qu'elle contient la séquence nucléotidique représentée à la figure 1B ou à la figure 1C, ou en ce qu'il s'agit d'une partie de la séquence représentée à la

figure 1B ou à la figure 1C, ladite partie de séquence codant pour un peptide reconnu par des anticorps présents dans le sérum d'un patient infecté par un rétrovirus HIV-2 ou étant utilisable comme sonde pour la détection dans un échantillon biologique, de la présence d'un rétrovirus HIV-2.

# Description

30

40

50

La présente invention est relative à des peptides ayant des propriétés immunologiques, le cas échéant immunogènes, en commun avec des antigènes susceptibles d'être obtenus sous une forme purifiée, à partir de virus capables de provoquer des lymphadénopathies susceptibles d'être relayées ensuite par le symdrôme d'immunodéficience acquise (SIDA) chez l'homme.

L'invention concerne en particulier des peptides antigéniques susceptibles d'être reconnus par des anticorps induits chez l'homme par des virus désignés par l'abréviation HIV, selon la nomenclature définie dans NATURE. Elle concerne également des peptides ayant des propriétés immunogènes ou susceptibles d'être rendus immunogènes in vivo, cette immunogénicité étant susceptible de se manifester par l'induction in vivo d'anticorps reconnaissant des antigènes caractéristiques des virus HIV-2 et même, au moins en ce qui concerne certains de ces peptides, des antigènes issus de HIV-1.

L'invention concerne en outre des applications de ces peptides à la fabrication de compositions pour le diagnostic in <u>vitro</u> chez l'homme de potentialité de certaines formes du SIDA et, en ce qui concerne certains d'entre eux, à la production de compositions immunogènes et de compositions vaccinantes contre les rétrovirus HIV.

De même l'invention concerne les applications aux mêmes fins des anticorps susceptibles d'être induits <u>in vivo</u> par les peptides immunogènes ou rendus immunogènes et, pour certains de ces anticorps, leurs applications à la production de principes actifs de médicaments contre ces SIDAS humains.

L'invention concerne également la mise en oeuvre de certains de ces peptides dans des procédés pour le diagnostic <u>in vitro</u> chez l'homme de certaines formes du SIDA, ainsi que leur application à la constitution de trousses ou "kits" de diagnostic.

Un premier rétrovirus dénommé LAV-1 ou HIV-1 a été isolé et décrit dans la demande de brevet GB.83/24.800 et une demande EP.84/401.834 du 14/09/84. Ce virus a également été décrit par F.Barre Sinoussi et al. dans Science, 220 n° 45-99, 20 pages 868-871.

Des variants de ce virus HIV-1 désignés par LAV ELI et LAV MAL, ont également été isolés, caractérisés et décrits dans la demande de brevet EP.84/-401.834.

Les virus HIV-1 et leurs variants possèdent les propriétés suivantes :

- ils ont pour cibles préférencielles les cellules Leu3 (ou lymphocytes T4) humaines et leurs cellules dérivées "immortalisées".
- ils ont une activité transcriptase inverse nécessitant la présence d'ions Mg<sup>2+</sup> et présentent une forte activité pour le poly(adenylate-oligo-deoxythymidylase) poly(A)-oligo(dT)12-18)
- ils ont une densité de 1,16 à 1,17 sur gradient de sucrose,
- ils ont un diamètre moyen de 139 nanomètres et un noyau de diamètre moyen de 41 nanomètres,
- les lysats de ces virus contiennent une protéine p25 (protéine du noyau) qui ne croise pas immunologiquement avec la protéine p24 de HTLV-1,
- ils contiennent une protéine p42 appartenant à leur enveloppe,
- ils contiennent également une glycoprotéine d'enveloppe gp110 d'un poids moléculaire de 110.000.

L'isolement et la caractérisation de rétrovirus appartenant à une classe distincte et n'ayant qu'une parenté immunologique réduite avec les précédents, ont été décrits dans la demande de brevet européen n° 87/400.151.4. Ces rétrovirus qui ont été regroupés sous la désignation HIV-2, ont été isolés chez plusieurs malades africains présentant des symptômes d'une lymphadénopathie ou d'un SIDA.

Les rétrovirus du type HIV-2 comme les rétrovirus du type HIV-1, se caractérisent par un tropisme pour les lymphocytes T4 humains et par un effet cytopathogène à l'égard de ces lymphocytes, lorsqu'ils s'y multiplient, pour alors causer soit des poly-adénopathies généralisées et persistantes, soit un SIDA.

Plus généralement les rétrovirus purifiés par HIV-2 possèdent en général les propriétés suivantes :

- la cible préférentielle des rétrovirus HIV-2 est constituée par les cellules Leu3 (ou lymphocytes T4) humaines et pour des cellules "immortalisées" dérivées de ces lymphocytes T4;
- ils sont cytotoxiques pour les lymphocytes T4 humains
- ils ont une activité de transcriptase inverse nécessitant la présence d'ions Mg<sup>2+</sup> et présentant une forte activité pour le poly(adénylate-oligodéoxythylmidylase) (poly(A)-oligo(dT) 12-18);
- ils ont une densité de 1,16 dans un gradient de sucrose ;
- ils ont un diamètre moyen de 140 nanomètres et un noyau ayant un diamètre moyen de 41 nanomètres;
  - ils peuvent être cultivés dans des lignées permanentes du type HUT ou exprimant la protéine T4;
  - ils ne sont pas infectieux pour les lymphocytes T8;
  - les lysats de ces virus contiennent une protéine p26 qui ne croise pas immunologiquement avec la protéine p24

du virus HTLV-I ou du virus HTLV-II;

10

15

20

40

- ces lysats contiennent en outre une protéine p16 qui n'est pas reconnue immunologiquement par la protéine p19 de HTLV-I ou de HTLV-II dans des essais de radioimmuno-précipitation;
- ils contiennent en outre une glycoprotéine d'enveloppe ayant un poids moléculaire de l'ordre de 130.000-140.000 qui ne croise pas immunologiquement avec la gp110 des HIV-1, mais qui en revanche croise immunologiquement avec la glycoprotéine d'enveloppe gp140 de STLV-III (virus isolé chez le singe);
- ces lysats contiennent encore des antigènes marquables par la <sup>35</sup>S-cystéine, dont les poids moléculaires s'étagent entre 32.000 et 42.000-45.000 : ils comprennent notamment un antigène ayant un poids moléculaire de l'ordre de 36.000 et un antigène ayant un poids moléculaire de l'ordre de 42.000, l'un de ces antigènes (p36 et p42) constituant vraisemblablement une glycoprotéine transmembranaire du virus HIV-2;
- l'ARN génomique des HIV-2 n'hybride pas avec l'ARN génomique de HIV-1 dans des conditions stringentes;
- dans des conditions non stringentes, l'ARN génomique de HIV-2 n'hybride, ni avec le gène env et le LTR qui le jouxte, de HIV-1, ni avec des séquences de la région pol du génome de HIV-1;
- dans des conditions non stringentes, il hybride faiblement avec des séquences de nucléotides de la région de HIV-1.

Un autre rétrovirus dénommé SIV-1, cette dénomination remplaçant la dénomination antérieurement connue STLV III, a été isolé chez le singe macaque rhésus. (M.D.Daniel et al. Science 228, 1201 (1985) N.L.Letwin et al, Science 230, 71 (1985) sous l'appellation "STLV-IIImac").

Un autre rétrovirus, désigné "STLV-III<sub>AGM</sub>", (ou SIV<sub>AGM</sub>) a été isolé chez des singes verts sauvages. Mais, contrairement au virus présent chez le singe macaque rhésus, la présence de "STLV-iii <sub>AGM</sub>" ne semble pas induire une maladie du type SIDA chez le singe vert d'Afrique.

Une souche du rétrovirus SIV-1 mac a été déposée à la CNCM le 7 Février 1986 sous le n° I-521. Des études ont montré que le rétrovirus SIV-1 comporte certaines protéines possédant une certaine parenté immunologique avec des protéines ou glycoprotéines structurales susceptibles d'être obtenues dans des conditions analogues, à partir de HIV-2. Ce rétrovirus SIV-1, dont on a constaté le caractère infectieux chez les singes, avait été désigné par STLVIII par les chercheurs qui l'ont isolé (références bibliographiques précitées).

Pour la commodité du langage, ces virus ne seront plus désignés dans ce qui suit que par l'expression SIV (l'expression SIV est l'abréviation anglaise de "Simian Immunodeficiency Virus" (virus d'immunodéficience du singe)) éventuellement suivi d'une abréviation désignant l'espèce de singe dont ils sont issus, par exemple, MAC (ou mac) pour le macaque ou AGM pour le singe vert d'Afrique (abréviation de "African Green Monkey").

En mettant en oeuvre les mêmes techniques que celles rappelées plus haut, il a été constaté que l'on pouvait également obtenir à partir de SIV-1mac :

- une protéine principale du noyau p27, ayant un poids moléculaire de l'ordre de 27 kilodaltons,
  - une glycoprotéine majeure d'enveloppe, gp140,
  - une protéine vraisemblablement transmembranaire p32, qui n'est guère observée en RIPA lorsque le virus a au préalable été marqué par la <sup>35</sup>S-cystéine, mais qui peut être observée dans les essais d'immunoempreintes (Western blots), sous forme de bandes larges.

Des études plus précises ont été réalisées en ce qui concerne les précédents virus HIV-2 et SIV. La poursuite de l'étude des rétrovirus HIV-2 a également conduit à l'obtention de séquences d'ADN complémentaires (ADNc) des ARNs de leurs génomes. La séquence nucléotidique complète de l'ADNc d'un rétrovirus représentatif de la classe HIV-2 (HIV-2 ROD) a été déposée le 21/02/-1986 à la CNCM sous le n° I-522, sous le nom de référence LAV-II ROD).

Cette séquence nucléotidique et les phases de lecture ouverte qu'elle contient sont indiqués à la figure 1 A. En outre, la poursuite de l'étude d'autres rétrovirus a également permis d'aboutir à l'obtention de leurs séquences nucléotidiques complètes. Il en est en particulier ainsi de l'ADNc dérivé de l'ARN génomique de SIV.

Le clonage et le séquençage du virus SIV-1 mac qui ont permis l'obtention de sa séquence nucléotidique ont été réalisés dans les conditions suivantes :

L'ADN de cellules HUT 78 infectées par le virus SIV (isolat STLV-III mac 142-83 décrit par Daniel et al.(1985) Science, <u>228</u>, p.1201-1204, digéré partiellement par l'enzyme de restriction Sau3A a été cloné au site BamHI du bactériophage vecteur Lambda ELBL3 pour constituer une banque génomique. Les 2 millions de phages recombinants de la banque génomique ainsi constituée ont été criblés <u>in situ</u> en conditions de sécurité P3, à l'aide de séquences du virus HIV2 provenant des clones lambda-ROD4, lambda-ROD35 et E2 (Clavel et al. (1986-Nature, <u>324</u>, p.691.) et nicktranslatées.

L'hybridation a été réalisée en 5xSSC à 50°C et les lavages en 2xSSC à 5°C. Un seul clone contenant l'ensemble des séquences virales a été obtenu. Ce clone est désigné par lambda-SIV-1. L'insérat du phage lambda-SIV-1 mesure 16,5 kb au total et comprend un provirus intégré auquel manquent seulement les 250 premières bases du LTR gauche,

alors que le LTR droit est complet.

45

50

Le provirus intégré a été séquencé par la méthode des didéoxynucléotides après sous-clonage de fragments aléatoires dans le phage M13mp8. 300 sous-clones ont été analysés.

Des fragments d'ADNc provenant du clone Lambda SIV-1 insérés dans des plasmides pSIV-1.1 et pSIV-1.2 ont été déposés à la CNCM le 15 Avril 1987, sous les numéros I-658 (pSIV-1.1) et I-659 (pSIV-1.2).

Les résultats ont été mentionnés dans les figures décrites ci-après.

La figure 1B représente la séquence nucléotidique du génome viral de SIV et les séquences qui en sont déduites pour les protéines virales correspondant aux produits des gènes gag, pol, env, Q, X, R, tat, art, F.

Les figures 3 à 11 et la figure 1C représentent les comparaisons des produits théoriques des gènes viraux et des LTR entre HIV2 et SIVmac. (λSIV-1).

L'invention concerne de plus les fragments d'ADNc déduits de l'ADNc issu du génome entier de SIV-1, ces fragments contenant une ou plusieurs séquences issues de la séquence complète d'ADNc et qui codent pour des peptides intéressants de l'invention. Ces séquences sont indiquées à la figure 1B et, à la figure 1C pour ce qui a trait à la séquence LTB du virus.

Les séquences nucléiques de l'ADNc de SIV ont été placées en correspondance avec les séquences nucléiques du virus HIV-2 ROD pour ce qui concerne la séquence LTR (figure 1C). Cette présentation que l'on retrouve pour le génome entier en rapprochant la figure 1B des figures 3 à 11 permet de repérer ou de déduire les acides nucléiques ayant des éléments de structure essentiels communs aux deux virus.

L'invention concerne naturellement aussi l'utilisation des cADNs issus de SIV ou de leurs fragments (ou de recombinants les contenant) en tant que sondes, pour le diagnostic de la présence ou non de virus HIV-2 dans des échantillons de sérums ou d'autres liquides ou tissus biologiques obtenus à partir de patients suspectés d'être porteurs du virus HIV-2. Ces sondes sont de préférence marquées également (marqueurs radio-actifs, enzymatiques, fluorescents, etc.). Des sondes particulièrement intéressantes pour la mise en oeuvre du procédé de diagnostic du virus HIV-2 ou d'un variant de HIV-2 peuvent être caractérisées en ce qu'elles comprennent la totalité ou une fraction de l'ADNc complémentaire du génome du virus SIV ou encore notamment les fragments recombinants contenus dans divers clones

Les sondes mises en œuvre dans ce procédé de diagnostic du virus HIV-2 et dans les kits de diagnostic ne sont en aucune façon réduites aux sondes décrites précédemment. Elles comprennent au contraire toutes les séquences nucléotidiques issues du génome du virus SIV, d'un variant de SIV ou d'un virus proche par sa structure, dès lors qu'elles permettent la détection dans des fluides biologiques de personnes susceptibles de développer un SIDA, d'anticorps dirigés contre un HIV-2 ou d'un virus qui en est proche.

La détection peut être réalisée de toutes façons en soi connues. Elle peut comprendre une mise en contact de ces sondes soit avec les acides nucléiques obtenus à partir des cellules contenues dans ces sérums ou autres milieux biologiques, par exemple liquides céphalo-rachidiens, salives, etc... Elle peut aussi comprendre une mise en contact de ces sondes avec ces milieux eux-mêmes dès lors que leurs acides nucléiques ont été rendus accessibles à l'hybridation avec ces sondes, et ce dans des conditions permettant l'hybridation entre ces sondes et ces acides nucléiques. L'étape finale du diagnostic in vitro comprend alors la détection de l'hybridation éventuellement produite. Le susdit diagnostic mettant en jeu des réactions d'hybridation peut également être réalisé à l'aide de mélanges de sondes respectivement originaires d'un HIV-2 et d'un SIV-1 ou d'un HIV-1, d'un HIV-2 et d'un SIV, dès lors qu'il n'est pas nécessaire de faire une différence entre le type de virus recherché.

D'une façon générale, le procédé de diagnostic de la présence ou non du virus HIV-2 ou d'un variant dans des échantillons de sérums ou d'autres liquides ou tissus obtenus à partir de patients suspectés d'être porteurs du virus HIV-2 comprend les étapes suivantes :

1/ au moins une étape d'hybridation conduite dans des conditions stringentes, par mise en contact de l'ADN de cellules de l'échantillon du patient suspect avec l'une des susdites sondes marquées sur une membrane appropriée,

2/ le lavage de ladite membrane avec une solution assurant la conservation de ces conditions stringentes de l'hybridation,

3/ la détection de la présence ou non du virus HIV-2 par une méthode d'immunodétection.

Dans un autre mode de réalisation préféré du procédé selon l'invention l'hybridation précitée est conduite dans des conditions non stringentes et le lavage de la membrane est réalisé dans des conditions adaptées à celles de l'hybridation.

Il va de soi que l'invention concerne les acides nucléiques correspondant à des séquences placées en des régions analogues de variants de SIV ainsi que tous les acides nucléiques dont les modifications résulteraient de la mise à profit de la dégénérescence du code génétique.

Les études comparatives qui ont aussi permis d'aboutir à des résultats relatifs aux protéines de noyau (core), ci-

après dénommées "protéines gag" et aux protéines d'enveloppes, ci-après dénommées "protéines env", ont également été rapportés dans la demande de brevet européen n° 87/400.151.4, déjà citée. Ces résultats montrent que les protéines du noyau (protéines gag) dans HIV-2 présentent des différences moins accentuées par rapport à celles des virus HIV-1, que les protéines d'enveloppe (protéines env). Globalement les protéines env dans HIV-2 se sont révélées présenter des parentés immunologiques extrêmement faibles, sinon inexistentes, avec les protéines env correspondantes des virus HIV-1.

Au contraire des études comparatives effectuées entre les structures des séquences d'ADNc des virus HIV-2 et SIV permettent de mettre en évidence certaines caractéristiques communes qui apparaissent au niveau des protéines. Globalement, les protéines de HIV-2 et de SIV-1 montrent des parentés immunologiques importantes.

La glycoprotéine majeure d'enveloppe de HIV-2 s'est révélée être plus proche immunologiquement de la glycoprotéine majeure d'enveloppe de SIV que de la glycoprotéine majeure d'enveloppe de HIV-1.

Ces constatations s'imposent non seulement au niveau des poids moléculaires: 130-140 kilodaltons pour les glycoprotéines majeures de HIV-2 et de SIV contre environ 110 pour la glycoprotéine majeure d'enveloppe de HIV-1, mais aussi au niveau des propriétés immunologiques, puisque des sérums prélevés à partir de malades infectés par HIV-2, et plus particulièrement des anticorps formés contre la gp140 de HIV-2 reconnaissent la gp140 de SIV-1mac, alors que dans des essais semblables les mêmes sérums et les mêmes anticorps de HIV-2 ne reconnaissent pas la gp110 de HIV-1. Mais les sérums anti-HIV-1 qui n'ont jamais réagi avec la gp140 de HIV-2 précipitent une protéine de 26 Kdal marquée par la 35S-cystéine, contenue dans les extraits de HIV-2.

La protéine majeure du noyau (core) de HIV-2 semble présenter un poids moléculaire moyen (environ 26.000) intermédiaire entre celui de la p25 de HIV-1 et la p27 de SIV.

Ces observations résultent des essais réalisés avec des extraits viraux obtenus à partir du HIV-2 isolé à partir de l'un des patients susmentionnés. Des résultats similaires ont été obtenus avec des extraits viraux du HIV-2 isolé à partir du second patient.

Des études plus poussées ont conduit les inventeurs à reconnaître une première classe de peptides ayant des séquences d'aminoacides soit identiques, soit proches de séquences contenues à l'intérieur des structures des protéines gag et env de HIV-2 ou de SIV voire de HIV-1. Ces peptides sont notamment applicables au diagnostic d'une infection chez l'homme par le virus HIV-2 ou de l'un de ses variants.

A cet égard la présente invention concerne également des procédés et des compositions de diagnostic pour la détection in vitro d'anticorps dirigés contre un virus HIV-2 ou de ses variants, plus particulièrement dans des échantillons biologiques, notamment des sérums de patients ayant subi une infection par le virus HIV-2, certains de ces peptides permettant une discrimination particulièrement poussée entre les infections dues à des virus HIV-2 et à des virus HIV-1.

Ces études poussées ont également conduit à la possibilité de synthétiser des peptides immunogènes ou susceptibles d'être rendus immunogènes, présentant des caractéristiques de structures leur permettant d'induire in vivo la production d'anticorps susceptibles de reconnaître des protéines env à la fois dans HIV-1 et dans HIV-2 et, au moins pour certains de ces peptides, de se fixer tant sur des virus HIV-1 que sur des virus HIV-2, plus particulièrement aux fins de les neutraliser. L'utilisation de ces derniers types de peptides est donc particulièrement indiquée pour la production de principes actifs de vaccins contre les virus HIV, donc contre le SIDA.

Pour désigner ci-après les résidus d'aminoacides entrant dans la constitution des peptides selon l'invention, on aura recours, pour ceux des acides aminés ayant une signification univoque à la nomenclature internationale désignant chaque acide aminé naturel par une lettre unique (lettre majuscule) selon le tableau des correspondances qui suit :

- M Méthionine
- L Leucine
- I Isoleucine
- V Valine

10

30

- F Phenylalanine
- S Sárina
- P Proline
- T Thréonine
- A Alanine Y Tyrosine
- H Histidine **Q** Glutamine
- N Asparagine
- 55 K Lysine

- - D Acide Aspartique
  - E Acide glutaminique
  - C Cystéine

W Tryptophane R Arginine G Glycine

10

20

30

35

40

Lorsqu'un acide aminé pourra, en raison de sa position au sein de la chaîne d'aminoacides caractéristique d'un peptide déterminé, prendre plusieurs significations, il pourra soit être désigné par un tiret "-", si sa signification peut être quelconque, soit par une lettre minuscule lorsque cet aminoacide pourra présenter un nombre limité de significations préférées, ce nombre étant cependant toujours supérieur à 1. Dans ce dernier cas, les significations possibles de cette lettre minuscule seront toujours précisées en rapport avec le peptide auquel il appartient.

Afin de faciliter la lecture, ces peptides seront désignés par une abréviation <u>env</u> ou <u>gag</u> suivie d'un indice numérique, par référence à des séquences d'aminoacides contenues, selon le cas, soit dans les protéines <u>env</u> soit dans les protéines <u>gag</u> de certains HIV-1, HIV-2 ou SIV. Il y sera encore fait référence dans ce qui suit.

Enfin dans les définitions qui suivent

- les groupes X représentent soit un groupe NH<sub>2</sub> libre ou amidé, notamment par un ou deux groupes alcoyle comprenant de 1 à 5 atomes de carbone, soit un groupe peptidique comprenant de 1 à 5 aminoacides, dont l'aminoacide N-terminal présente lui-même un groupe NH<sub>2</sub> libre ou amidé comme précédemment indiqué, et
  - les groupes Z représentent, soit un groupe -OH libre ou alcoxyle et contenant alors un groupe alcoyle comprenant de 1 à 5 atomes de carbone, soit un groupe peptidique comprenant de 1 à 5 aminoacides, dont l'aminoacide Cterminal présente lui-même un groupe -OH libre ou alcoxyle, comme précédemment indiqué, les groupes de 1 à 5 acides aminés le cas échéant contenus dans X ou Z ou dans les deux à la fois étant tels, que leur présence n'est pas incompatible avec la préservation pour l'essentiel des propriétés immunologiques, le cas échéant immunogènes, des peptides qui en sont dépourvus.

Les peptides selon l'invention, qui ont en commun des propriétés immunologiques avec des antigènes de HIV-2 et, pour certains d'entre eux également avec des antigènes de HIV-1 ou de ses variants, sont caractérisés en ce qu'ils ont égaement une structure peptidique en commun avec les antigènes de SIV. De façon avantageuse, ces peptides comprennent normalement au plus 40 résidus d'acides aminés.

Des peptides préférés sont les suivants :

45

50

```
env1
       XRV-AIEKYL-DQA-LN-WGCAFRQVCZ
       env2
5
       X-LE-AQI-QQEKNMYELQKLNZ
       env3
      XELGDYKLVEITPIG-APT--KR----Z
10
      env4
      X----VTV-YGVP-WK-AT--LFCA-Z
      <u>env5</u>
15
      X---QE--L-NVTE-F--W-NZ
      env6
      XL---S-KPCVKLTPLCV--Z
      env7
20
      X---N-S-IT--C-K---Z
      env8
      X-I---YC-P-G-A-L-C-N-TZ
25
      <u>env9</u>
      X-----A-C----W--Z
      env10
30
      X-G-DPE----NC-GEF-YCN----NZ
35
       env11
       X----C-IKQ-I-----G---YZ
```

40 Plus particulièrement l'invention concerne les peptides suivants :

50

45

```
env1
       XRV-AIEKYL-DQA-LN-WGCAFRQVC2
       env2
5
       X-LE-AQIQQEKNMYELQKLNZ
       env3
       XELGDYKLVEITPIG-APT--KR----Z
10
       env4
       X----VTV-YGVP-W--AT--LFCA-Z
       env5
15
       X---E--L-NVTE-F--W-NZ
       env6
       XL---S-KPCVKL-PLC---Z
20
       env7
       X---N-S-I---C-K----Z
       env8
       X-I---YC-P-G-A-L-C-N-TZ
25
       env9
       X-----W--2
       <u>env10</u>
30
       X-G-DPE----NC-GEF-YC----NZ
       env11
       X----G-I-Q-I----G---YZ
35
      Des peptides avantageux correspondant aux précédents, présentent les formules qui suivent :
       env1
40
       XRVTAIEKYLQDQARLNSWGCAFRQVCZ, ou
       XRVTAIEKYLKDQAQLNAWGCAFRQVCZ
       env2
       XSLEQAQIQQEKNMYELQKLNSWZ, ou
45
       XLLEEAQIQQEKNMYELQKLNSWZ
```

<u>env3</u>

50

XELGDYKLVEITPIGFAPTKEKRYSSAHZ, OU XELGDYKLVEITPIGLAPTNVKRYTTG-Z

<sup>(</sup>On remarquera que les peptides env1, env2, env3 attestent de la très grande parenté entre HIV-2 et SIV-1. En effet le premier peptide est inclu dans le génome de HIV-2 et le second, dans celui de SIV-1).

# env4 XabcdVTVeYGVPfWogAThiLFCAjZ, dans lesquels les lettres de a à j peuvent avoir les significations suivantes : a est C, E ou D b est T, K, D, N ou I c est Q ou L 10 d est Y ou W e est F ou Y fest T, V ou A g est N ou E h est I ou T 15 i est P ou T j est T ou S o est K ou R env5 20 XabcoEdeLfNVTEgFhiwjN2, dans lequel les lettres de a à j peuvent avoir les significations suivantes : 25 a est D ou P b est D ou N c est Y ou P d est I, V, I ou L e est T, V, E ou A f est V, G ou E ou g est A, N, G ou S h est D ou N i est A ou M jest N, K ou E 35 o est Q ou S <u>env6</u> XLabcSdKPCVKLoPLCuefKZ, 40

dans lequel les lettres de a à f peuvent avoir les significations suivantes :

a est F ou W 45 b est E ou D c est T ou Q d est I ou L e est A, S ou T f est M ou L 50 o est T ou S u est V ou I

55

env7

XabCNxSyIocdCeRfghiZ,

dans lequel les lettres de a à i et x et y peuvent avoir les significations suivantes : a est N ou T ou I

```
b est H ou S ou N
         c est E ou Q
         d est S, A ou C
         e est D ou P
5
         f est H, V ou D
         g est Y ou S
         h est W ou F
         i est D ou E
         x est T ou R
10
         y est V ou A
         o est T ou Q
                                         env8
15
                                         XaIbcdYCxPeGfAgLhCiNjT2,
         dans lequel les lettres de a à k et x peuvent avoir les significations suivantes :
         a est A ou P
20
         b est R ou P
         c est F, I ou C
         d est R ou H
         e est P ou A
         fest You F
25
         g est L ou I
         h est R ou K
         i est - ou N
         j est D ou K
         x est A ou T
                                            env9
                                            XwabcxyAdCefghizWjkZ,
35
         dans lequel les lettres de a à k et x à z peuvent avoir les significations suivantes :
         a est K ou - ou E
         b est R ou -
         c est P ou M ou I
40
         d est W ou H ou Y
         e est W ou N ou T ou R
         f est F ou I
         g est K ou S ou N ou G
         h est G ou R ou E
45
         i est - ou A ou T
         j est K ou N ou D ou S
         k est D ou A ou N ou K ou E
         w est N, D ou I
         x est R ou G ou K
50
         y est Q ou K ou R
         z est K ou E ou Q ou N
```

dans lequel les lettres de a à n et x peuvent avoir les significations suivantes :

env10

55

XaGbDPEcdefghNCiGEFjYCokxlmnNZ,

a est K ou - ou G b est S ou G ou c est V ou I d est A ou V ou T 5 e est Y ou T ou M ou F fiest Miou Hi g est W ou S h est T ou F i est R ou G 10 j est L ou F o est N ou K k est M ou S lest W ou Q ou K ou G m est F ou l 15 n est L ou F x est T ou S ou N

#### env11

# XabcdwCeIoQfIxgyhizGjklY2,

dans lequel les lettres de a à 1 et w à z peuvent avoir les significations suivantes :

a est R ou T ou S ou N

25 b est N ou l

20

35

45

c est Y ou T

d est A ou L ou V

e est H ou R

fest I ou F

g est T ou M

h est H ou Q ou A

i est K ou E

i est R ou K

k est N ou A

lest Vou M

w est P ou Q

x est N ou K

y est W ou V

z est V ou T ou K

40 o est K ou R

La structure du peptide antigénique codé par le gène gag et désigné par gag1 est également représentée ci-après :

# XDCKLVLKGLGaNPTLEEMLTAZ,

dans lequel la lettre a désigne M ou T.

Il sera remarqué que, d'une façon générale, les aminoacides ayant une signification univoque (donc représentés par une lettre majuscule correspondant à la nomenclature internationale) qui interviennent dans les définitions qui précèdent des peptides selon l'invention, se trouvent être la correspondance avec des aminoacides identiques placés dans le même ordre dans les séquences env ou gag correspondantes de la protéine env ou gag d'au moins l'un des HIV. ou de SIV-1.

Les positions de ces séquences sont soulignées et repérées au sein des séquences d'aminoacides des protéines env respectivement de HIV-2 ROD (CNCM nº I-532) et HIV-1 BRU (CNCM nº I-232) représentées à la figure 2. Par ailleurs, les alignements des acides aminés des protéines env et gag respectivement de SIV-1mac (CNCM n° I.521) et de HIV-2 ROD sont présentées à la figure 3 et à la figure 4.

Les traits pleins qui apparaissent en certaines localisations de ces séquences visent à souligner que certains aminoacides contenus dans ces séquences ont été volontairement délétés au plan de la présentation, afin de permettre

la mise en alignement d'aminoacides respectivement identiques (alors marqués d'un astérisque) ou de deux points verticaux sur une même ligne verticale dans les séquences des protéines correspondantes de HIV-1 et de HIV-2 d'une part, de SIV et de HIV-2 d'autre part.

Outre les peptides précités, l'invention concerne également les peptides modifiés par insertion et/ou délétion et/ou substitution d'un ou plusieurs acides aminés, pour autant que les propriétés antigéniques ou immunogènes desdits peptides ne sont pas modifiées, ou que les propriétés de reconnaissance de l'antigène ou de l'anticorps avec lesdits peptides ne sont pas substantiellement modifiées.

Dans un mode de réalisation particulièrement préféré, l'invention concerne des peptides ayant des propriétés immunologiques en commun avec l'ossature peptidique de la glycoprotéine d'enveloppe des virus de la classe HIV-2, ces peptides contenant un nombre de résidus d'acides aminés n'excédant pas 40.

Ces peptides préférés selon l'invention ont les séquences suivantes :

15	env1 RVTAIEKYLQDQARLNSWGCAFRQVC AIEKYLQDQ RVSAIEKYLKDQAQLNAWGCAFRQVC
20	AIEKYLKDQ
25	GUAS STEĞYĞIĞĞEKNWAETĞKTURM FIFEYĞIĞĞEKNWAETĞKTURM
30	env3 Elgdyklveitpigfaptkekryssah Yklveitpigfaptkek
35	ELGDYKLVEITPIGLAPTNVKRYTTG- YKLVEITPIGLAPTNVK
40	eny4 CTQYVTVFYGVPTWKNATIPLFCAT VTVFYGVPTWKNAT CIQYVTVFYGVPAWRNATIPLFCAT VTVFYGVPAWRNAT
50	EKLWVTVYYGVPVWKEATTTLFCAS VTVYYGVPVWKEAT EDLWVTVYYGVPVWKEATTTLFCAS VTVYYGVPVWKEAT
55	DNLWVTVYYGVPVWKEATTTLFCAS VTVYYGVPVWKEAT

	env5
	DDYQEITL-NVTEAFDAWNN
5	L-NVTEAF
	DDYSELAL-NVTESFDAWEN
	L-NVTESF
10	PNPQEVVLVNVTENFNMWKN
10	LVNVTENF
	PNPQEIELENVTEGFNMWKN
	LENVTEGF
15	PNPQEIALENVTENFNMWKN
	LENVTENF
20	env6
	ETSIKPCVKLTPLCVAMK
	ETSIKPCVKLSPLCITMR
25	DQSLKPCVKLTPLCVSLK
	DQSLKPCVKLTPLCVTLN
	PCVKLTPLCV
30	<u>env7</u>
	NHCNTSVITESCD
	NTSVIT
35	NHCNTSVIQECCD
	NTSVIQ
	TSCNTSVITQACP
40	NTSVIT
	INCNTSVITQACP
	NTSVIT
45	INCNTSAITQACP
	NTSAIT
50	env8
	YCAPPGYALLRC-NDT
	YCAPAGFAILKCNNKT
55	YCAPAGFAILKCNDKK
<del></del>	YCAPAGFAILKCRDKK

	env9
	NKRPRQAWCWFKG-KWKD
5	NERPKQAWCRFGG-NWKE
	NMRQAHCNISRAKWNA
	DIRRAYCTINETEWDK
10	IIGQAHCNISRAQWSK
	env10
	KGSDPEVAYMWTNCRGEFLYCNMTWFLN
15	· NCRGEFLYCN
	GG-DPEVTFMWTNCRGEFLYCKMNWFLN
	NCRGEFLYCK
20	-ggdpeivthsfncggeffycnstqlfn
	NCGGEFFYCN
	-GGDPEITTHSFNCRGEFFYCNTSKLFN
25	NCRGEFFYCN
	-GGDPEITTHSFNCGGEFFYCNTSGLFN
	NCGGEFFYCN
30	4
	env11
	RNYAPCHIKQIINTWHKVGRNVY
35	CHIKQII
	RNYVPCHIRQIINTWHKVGKNVY
	CHIRQII
	TITLPCRIKQFINMWQEVGKAMY
40	CRIKQFI
	SITLPCRIKQIINMWQKTCKAMY CRIKQII
	NITLQCRIKQIIKMVAGR-KAIY
45	CRIKOII
	CUTUÄTT
	gag1
50	DCKLVLKGLGTNPTLEEMLTA

55

Les peptides selon l'invention peuvent encore avantageusement être préparés par les techniques classiques, dans le domaine de la synthèse des peptides. Cette synthèse peut être réalisée en solution homogène ou en phase solide.

Par exemple, on aura recours à la technique de synthèse en solution homogène décrit par HOUBENWEYL dans l'ouvrage intitulé "Méthode der Organischen Chemie" (Méthode de la Chimie Organique) édité par E. Wunsch, vol. 15-l et II., THIEME, Stuttgart 1974.

Cette méthode de synthèse consiste à condenser successivement deux-à-deux les aminoacyles successifs dans

l'ordre requis, ou à condenser des aminoacyles et des fragments préalablement formés et contenant déjà plusieurs aminoacyles dans l'ordre approprié, ou encore plusieurs fragments préalablement ainsi préparés, étant entendu que l'on aura eu soin de protéger au préalable toutes les fonctions réactives portées par ces aminoacyles ou fragments, à l'exception des fonctions amines de l'un et carboxyles de l'autre ou vice-versa, qui doivent normalement intervenir dans la formation des liaisons peptidiques, notamment après activation de la fonction carboxyle, selon les méthodes bien connues dans la synthèse des peptides. En variante, on pourra avoir recours à des réactions de couplage mettant en jeu des réactifs de couplage classique, du type carbodiimide, tels que par exemple la 1-éthyl-3-(3-diméthyl-amino-propyl)-carbodiimide. Lorsque l'aminoacyle mis en oeuvre possède une fonction acide supplémentaire (notamment dans le cas de l'acide glutamique), ces fonctions seront par exemple protégées, par des groupes t-bustylester.

Dans le cas de la synthèse progressive, acide aminé par acide aminé, la synthèse débute de préférence par la condensation de l'amino-acide C-terminal avec l'aminoacide qui correspond à l'aminoacyle voisin dans la séquence désirée et ainsi de suite, de proche en proche, jusqu'à l'acide aminé N-terminal. Selon une autre technique préférée de l'invention, on a recours à celle décrite par R.D. MERRIFIELD dans l'article intitulé "Solid phase peptide synthesis" (J. Am. Soc., 45, 2149-2154).

10

15

Pour fabriquer une chaîne peptidique selon le procédé de MERRIFIELD, on a recours à une résine polymère très poreuse, sur laquelle on fixe le premier acide aminé C-terminal de la chaîne. Cet acide aminé est fixé sur la résine par l'intermédiaire de son groupe carboxylique et sa fonction amine est protégée, par exemple par le groupe t-butyloxy-carbonyle.

Lorsque le premier acide aminé C-terminal est ainsi fixé sur la résine, on enlève le groupe protecteur de la fonction amine en lavant la résine avec un acide.

Dans le cas où le groupe protecteur de la fonction amine est le groupe t-butyloxycarbonyle, il peut être éliminé par traitement de la résine à l'aide d'acide trifluoroacétique.

On couple ensuite le deuxième acide aminé qui fournit le second amino-acyle de la séquence recherché, à partir du résidu amino-acyle C-terminal sur la fonction amine déprotégée du premier acide aminé C-terminal fixé sur la chaîne. De péférence, la fonction carboxyle de ce deuxième acide aminé est activée, par exemple par la dicyclohexyl-carbodiimide, et la fonction amine est protégée, par exemple par le t-butyloxycarbonyle.

On obtient ainsi la première partie de la chaîne peptidique recherchée, qui comporte deux acide aminés, et dont la fonction amine terminale est protégée. Comme précédemment, on déprotège la fonction amine et on peut ensuite procéder à la fixation du troisième aminoacyle, dans les conditions analogues à celles de l'addition du deuxième acide aminé C-terminal.

On fixe ainsi, les uns après les autres, les acides aminés qui vont constituer la chaîne peptidique sur le groupe amine chaque fois déprotégé au préalable de la portion de la chaîne peptidique déjà formée, et qui est rattachée à la récipe.

Lorsque la totalité de la chaîne peptidique désirée est formée, on élimine les groupes protecteurs des différents acide aminés constituant la chaîne peptidique et on détache le peptide de la résine par exemple à l'aide d'acide fluorydrique.

L'invention concerne également les oligomères hydrosolubles des peptides monomères sus-indiqués. L'oligomérisation peut provoquer un accroissement de l'immunogénicité des peptides monomères selon l'invention. Sans qu'une telle indication chiffrée puise être considérée comme limitative, on mentionnera néanmoins que ces oligomères peuvent, par exemple, contenir de 2 à 10 unités monomères.

Les unités monomères entrant dans cet oligomère sont soit toutes constituées par le polypeptide de séquence 1 ou par le polypeptide de séquence 2, soit par l'un et l'autre de ces polypeptides.

On peut avoir recours, pour réaliser l'oligomérisation, à toute technique de polymérisation couramment utilisée dans le domaine des peptides, cette polymérisation étant conduite jusqu'à l'obtention d'un oligomère ou polymère contenant le nombre de motifs monomères requis pour l'acquisition de l'immunogénicité désirée.

Une méthode d'oligomérisation ou de polymérisation du monomère consiste dans la réaction de celui-ci avec un agent de réticulation tel que le glutaraldéhyde.

On peut également avoir recours à d'autres méthodes d'oligomérisation ou de couplage, par exemple à celle mettant en jeu des couplages successifs d'unités monomères, par l'intermédiaire de leurs fonctions terminales carboxyle et amine en présence d'agents de couplage homo- ou hétéro- bifonctionnels.

On peut également pour la production de molécules comportant un ou plusieurs motifs de 17 acides aminés tels que définis ci-dessus, avoir recours à des techniques du génie génétique mettant en œuvre des micro-organismes transformés par un acide nucléique déterminé comprenant des séquences nucléotidiques appropriées correspondantes.

L'invention concerne également les acides nucléiques contenant une ou plusieurs séquences issues de la séquence de l'ADNc du virus HIV-2 ROD. Ces séquences repérées par la numérotation figurant sur la séquence précédemment décrite, codent pour certains peptides intéressants de l'invention.

	Séquence	codant	pour	env1	nucléotides	7850	à	7927
	•			env2	•	8030	à	8095
5	•	•		<u>env3</u>		7601	à	7636
	•	•		env4	•	6170	à	6247
	n	•		env5	•	6294	à	6349
10		•		env6		6392	à	6445
	n	•		env7		6724	à	6763
	•	•		env8	•	6794	à	6838
	•	•		env9	•	7112	à	7162
15	*			env10	•	7253	à	7336
	*	•		env1	<u>"</u>	7358	à	7426
	•	•		gag1	•	1535	à	1597

20

L'invention concerne enfin les acides nucléiques correspondants du virus SiV, contenant une ou plusieurs séquences issues de l'ADNc du virus SIV-1. Ces séquences codant pour les peptides <u>env1</u> à <u>env11</u> et <u>gag1</u> peuvent être repérés sur la figure 3 par comparaison avec les séquences correspondantes décrites pour HIV-2.

Il va de soi que l'invention concerne les acides nucléiques correspondant à des séquences placées en des régions analogues des ADNc dérivés de variants de HIV-2 ROD ou de SIV, ainsi que tous les acides nucléiques dont les modifications vis à vis des précédents résulteraient de la mise à profit de la dégénérescence du code génétique.

L'invention concerne encore les conjugués obtenus par couplage covalent des peptides selon l'invention (ou des susdits oligomères) à des molécules porteuses (naturelles ou synthétiques), physiologiquement acceptables et non toxiques, par l'intermédiaire de groupements réactifs complémentaires respectivement portés par la molécule porteuse et le peptide. Des exemples de groupements appropriés sont illustrés dans ce qui suit :

A titre d'exemple de molécules porteuses ou supports macromoléculaires entrant dans la constitution des conjugués selon l'invention, on mentionnera des protéines naturelles, telles que l'anatoxine tétanique, l'ovalbulmine, des sérums albumines, des hémocyamines, etc...

A titre de support macromoléculaires synthétiques, on mentionnera par exemple des polylysines ou des poly(D-L-alanine)-poly(L-lysine).

La littérature mentionne d'autres types de supports macromoléculaires susceptibles d'être utilisés, lesquels présentent en général un poids moléculaire supérieur à 20 000.

Pour synthétiser les conjugués selon l'invention, on peut avoir recours à des procédés connus en soi, tels que celui décrit par FRANTZ et ROBERTSON dans Intect. and Immunity, 33, 193-198 (1981), ou celui décrit dans Applied and Environmental Microbiology, (octobre 1981), vol. 42, n° 4, 611-614 par P.E. KAUFFMAN en utilisant le peptide et la molécule porteuse appropriée.

Dans la pratique, on utilisera avantageusement comme agent de couplage les composés suivants, cités à titre non limitatif : aldéhyde glutarique, chloroformiate d'éthyle, carbodiimides hydrosolubles [N-éthyl-N'(3-diméthylamino-propyl) carbodiimide, HCI], diisocyanates, bis-diazobenzidine, di- et trichloro-s-triazines, bromures de cyanogène, ainsi que les agents de couplage mentionnés dans Scand. J. Immunol., (1978), vol. 8, p. 7-23 (AVRAMEAS, TERNYNCK, GUESDON).

On peut avoir recours à tout procédé de couplage faisant intervenir d'une part une ou plusieurs fonctions réactives du peptide et d'autre part, une ou plusieurs fonctions réactives de molécules supports. Avantageusement, il s'agit des fonctions carboxyle et amine, lesquelles peuvent donner lieu à une réaction de couplage en présence d'un agent de couplage du genre de ceux utilisés dans la synthèse des protéines, par exemple, le 1-éthyl-3-(3-diméthylaminopropyl) carbodiimide, le N-hydroxybenzotriazole, etc... On peut encore avoir recours à la glutaraldéhyde, notamment lorsqu'il s'agit de relier entre eux des groupes aminés respectivement portés par le peptide et la molécule support.

Les peptides selon l'invention possèdent des propriétés antigéniques. Ils peuvent donc être utilisés dans des procédés de diagnostic pour la détection d'une infection par le virus HIV-2.

Comme on l'a déjà mentionné, des études ont permis de distinguer deux groupes de peptides pouvant être mis en oeuvre dans des procédés de détection d'anticorps contre le virus HIV-2 dans un fluide biologique humain, notamment un sérum ou un liquide céphalo-rachidien.

Un premier groupe (I) comprend les peptides gag1. Ces peptides reconnaissent des anticorps anti-HIV-2 et sont

donc capables de détecter une infection par HIV-2. Ils reconnaissent également dans une certaine mesure des anticorps anti-HIV-1.

Un second groupe (II) comprend des peptides qui correspondent plus particulièrement à ceux qui sont situés dans la partie transmembranaire et dans la fin de la partie externe de la protéine d'enveloppe. Ces peptides sont ceux précédemment désignés par env1, env2 et env3. Ils permettent la reconnaissance spécifique de la présence d'anticorps contre HIV-2 et permettent donc de discriminer chez une personne les infections passées ou présentes dues à un HIV, plus particulièrement entre celles qui ont été provoquées par un HIV-2 et celles qui l'ont été par un HIV-1.

L'invention concerne également une composition contenant au moins l'un des susdits peptides ou au moins un oligomère de ce peptide, caractérisée en ce qu'elle a la capacité d'être reconnue par des sérums d'origine humaine contenant des anticorps contre le virus HIV-2.

L'invention concerne un procédé de diagnostic in vitro un ou des peptides selon l'invention pour la détection d'anticorps contre HIV-2 dans des fluides biologiques, en particulier dans des sérums humains.

D'une façon générale le procédé de diagnostic in vitro ci-dessus comprend les étapes suivantes :

- la mise en contact de ce liquide biologique avec lesdits peptides,
  - la détection de la présence éventuelle d'un complexe peptide-anticorps par des méthodes physiques ou chimiques, dans ledit liquide biologique.

Dans un mode de réalisation préféré de l'invention, la détection du complexe antigène-anticorps est réalisée grâce à des tests immunoenzymatiques (du type ELISA), immunofluorescents (du type IFA), radioimmunologiques (du type RIA) ou des tests de radioimmunoprécipitation (du type RIPA).

Ainsi l'invention concerne également tout peptide selon l'invention marqué à l'aide d'un marqueur adéquat du type enzymatique, fluorescent, radioactif, etc...

De telles méthodes comprennent par exemple les étapes suivantes :

25

- dépôt de quantités déterminées d'une composition peptidique selon l'invention dans les puits d'une microplaque de titration.
- introduction dans lesdits puits de dilutions croissantes du sérum devant être diagnostiqué,
- incubation de la microplaque,
- rinçages répétés de la microplaque,
  - introduction dans les puits de la microplaque d'anticorps marqués contre des immunoglobulines du sang, le marquage de ces anticorps ayant été réalisé à l'aide d'une enzyme sélectionnée parmi celles qui sont capables d'hydrolyser un substrat en modifiant l'absorption des radiations de ce dernier, au moins à une longueur d'onde déterminée.
- détection, en comparaison avec un témoin de contrôle, de la quantité de substrat hydrolysé.

L'invention concerne également des coffrets ou kits pour le diagnostic <u>in vitro</u> de la présence d'anticorps contre les virus HIV-2 et, dans certains cas, HIV-1 dans un milieu biologique qui comprennent;

- 40 une composition peptidique selon l'invention,
  - les réactifs pour la constitution du milieu propice à la réalisation de la réaction immunologique,
  - les réactifs permettant la détection du complexe antigènes-anticorps produit par la réaction immunologique. De tels réactifs peuvent également porter un marqueur, ou être susceptibles d'être reconnus à leur tour par un réactif marqué. Plus particulièrement dans le cas où la composition polypeptidique sus-mentionnée n'est pas marquée.
- un tissu fluide biologique de référence dépourvu d'anticorps reconnus par la composition polypeptidique sus-mentionnée,

L'invention concerne les anticorps eux-mêmes formés contre les peptides de l'invention.

Il va de soi que cette production n'est pas limitée aux anticorps polyclonaux.

Elle s'applique encore à tout anticorps monoclonal produit par tout hybridome susceptible d'être formé, par des méthodes classiques, à partir des cellules spléniques d'un animal, notamment de souris ou de rat, immunisés contre l'un des peptides de l'invention, d'une part et des cellules d'une lignée de cellule myélome approprié d'autre part, et d'être sélectionné, par sa capacité à produire des anticorps monoclonaux reconnaissant le peptide initialement mis en oeuvre pour l'immunisation des animaux.

L'invention concerne également des compositions immunogènes pour la production de vaccins dont le principe actif est constitué par au moins un peptide selon l'invention, ou un oligomère de ce peptide, ou un peptide sous forme conjuguée avec une molécule porteuse, caractérisées en ce qu'elles induisent la production d'anticorps contre les susdits peptides en quantité suffisante pour aussi inhiber les protéines du rétrovirus HIV-2, voire même le rétrovirus

HIV-2 entrant en association avec un véhicule pharmaceutiquement acceptable.

Les compositions immunogènes pour la production de vaccins comprennent de façon avantageuse plus particulièrement au moins l'un des peptides précédemment désignés par env4, env5, env6, env7, env8, env9, env10, env11 voir des mélanges de ceux-ci.

Parmi ces peptides aptes à constituer des principes actifs de vaccins certains sont particulièrement préférés car ils possèdent une structure de base en acides aminés correspondant à des régions des glycoprotéines d'enveloppe qui présentent un important degré de conservation, non seulement dans les HIV-2, et dans les SIV, mais également dans les HIV-1. Ces peptides particulièrement préférés sont les peptides désignés par env4, certains peptides env5, env6 et env10.

Dans un mode de réalisation préféré de l'invention les peptides immunogènes (ou fragments de ces peptides) aptes à constituer des principes actifs de vaccins sont choisis parmi ceux dont les formules correspondent à des séquences qui, dans les glycoprotéines d'enveloppe de HIV-2, SIV et HIV-1 présentant une homologie en acides aminés supérieure à 50%, qui appartiennent à la partie externe de l'enveloppe du virus, qui sont dépourvus ou presque de délétions, et qui renferment des résidus de cystéine favorables à la stabilisation des liaisons et à la constitution de boucles d'ancrage.

Les peptides suivants appartiennent à cette catégorie de peptides préférés.

20	<u>env4</u> XVTV-YGVP-WATZ
25	<u>env5</u> XL-NVTE-FZ
30	<u>env6</u> XKPCVKL-PLC-2
35	<u>env7</u> XN-S-I-Z
	env10 XNC-GEF-YC-2
40	<u>env11</u> XC-I-Q-IZ

10

45

Des compositions pharmaceutiques avantageuses sont constituées par des solutions, suspensions ou liposomes injectables contenant une dose efficace d'au moins un produit selon l'invention. De préférence, ces solutions, suspensions ou liposomes sont réalisés dans une phase aqueuse stérilisée isotonique, de préférence saline ou glucosée.

L'invention concerne plus particulièrement de telles suspensions, solutions ou forme liposome qui sont aptes à être administrées par injections intradermiques, intramusculaires ou sous-cutanées, ou encore par scarifications.

Elle concerne également des compositions pharmaceutiques administrables par d'autres voies, notamment par voie orale.

Les compositions pharmaceutiques selon l'invention, utilisables en tant que vaccins pour être efficaces dans la production d'anticorps contre le virus HIV-2, peuvent à titre d'exemple être administrées à des doses situées entre 10 et 500 μg/kg, de peptides selon l'invention, de préférence de 50 à 100 μg/kg.

Ces doses sont citées à titre d'exemple et ne possèdent en aucun cas un caractère limitatif.

Comme on l'a déjà indiqué plus haut les différents peptides qui ont été définis peuvent comprendre des modifications qui n'ont pas pour effet de modifier de façon fondamentale leurs propriétés immunologiques. Les peptides équi-

valents qui en résultent entrent dans le champ des revendications qui suivent. A titre d'exemples de peptides équivalents on mentionnera ceux dont les structures en correspondance avec des régions des ADNc d'autres variants de HIV-2 de SIV ou de HIV-1, lorsque ces régions ont été mises en alignement dans des conditions semblables à celles qui ont été évoquées ci-dessus, à propos de HIV-2 ROD, SIV et HIV-1 BRU. A titre d'autres de ces peptides, on mentionnera ceux dont les structures sont en correspondance avec de telles régions dans les ADNc qui ont fait l'objet de dépôts à la CNCM, notamment sous les numéros I-502, I-642 (HIV-2 IRMO), I-643 (HIV-2 EHO) ainsi que, dans les cas appropriés, des variants de HIV-1 qui ont fait l'objet de dépôts à la CNCM sous les numéros I-232, I-240, I-241, I-550, I-551.

Les peptides selon l'invention peuvent encore être définis par les formules suivantes (dans lesquels X, Z et les tirets "-" ont les significations sus-indiquées) :

XRV-AIEKYL-DQA-LN-WGCAFRQVCZ XAIEKYL-DZ

5

X-LE-AQIQQEKNMYELQKLNSWZ XQIQQEKNZ

10

XELGDYKLVEITPIG-APT--KR----Z XYKLVEITPIG-APT--KRZ

15

X----VTV-YGVP-W--AT--LFCA-Z XVTV-YGVP-W--ATZ

25

30

35

40

NKRPRQAWCWFKG-KWKD

45

50

55

L'invention concerne également outre les peptides de SIV déjà décrits, les protéines codées par l'ADNc du virus SIV. Elle concerne également les protéines de tout virus immunologiquement étroitement apparenté à SIV-1mac, en particulier tout virus dont les protéines et les glycoprotéines d'enveloppe croisent immunologiquement et dont les ADNc présentent un pourcentage d'homologie d'au moins 95% et de préférence d'au moins 98%.

En particulier l'invention concerne :

1/ les protéines et glycoprotéines de l'enveloppe codées par le gène env et représentées à la figure 3, 2/ la protéine GAG représentée à la figure 4,

3/ la protéine POL représentée à la figure 5,

4/ la protéine Q représentée à la figure 6,

5/ la protéine R représentée à la figure 7,

6/ la protéine X représentée à la figure 8,

7/ la protéine F représentée à la figure 9,

5

35

8/ la protéine TAT représentée à la figure 10,

Les acides aminés des protéines précitées de SIV, ont été représentées en alignement avec les séquences d'acides aminés des protéines correspondantes du virus HIV-2 les points verticaux figurant entre les deux séquences correspondent aux acides aminés communs entre les protéines des deux virus.

Les séquences d'ADNc codant pour les protéines précitées apparaissent sur la figure 1B. L'invention concerne, outre les séquences nucléiques précitées toute séquence nucléiques modifiée, qui code également pour les protéines du rétrovirus SIV ou d'un variant.

Ces séquences d'ADNc repérées par la numérotation figurant sur les séquences décrites précédemment (figure 1B) sont les suivantes :

	-séqu	ence	codant	pour	GAG,	nucléotides	551 8	ì i	2068
20	-	*			POL,		1726	à	4893
	-	*			Q,	ii.	4826	à	5467
	-	U	н		Χ,	a	5298	à	5633
	-	н	•		R,	tt	5637	à	5939
25	-	**			F,	ч	8569	à	9354
	-	**			TAT-1	ı "	5788	à	6084
	-	н			ART-1	•	6014	à	6130
30	-	•	•		TAT-2	2 "	8296	à	8391
	-	н	•		ART-2	2 "	8294	à	8548
	-		•		ENV	•	6090	à	8732

L'invention concerne donc naturellement les protéines précédemment décrites, lorsqu'elles sont obtenues à partir du virus SIV ou lorsqu'elles sont préparées par une méthode de synthèse, notamment par l'une des méthodes déjà citées en rapport avec la synthèse des peptides de plus petite taille.

L'invention concerne également l'utilisation des protéines précédentes pour le diagnostic de la présence éventuelle d'anticorps dirigés contre les protéines de HIV-2, voire contre HIV-2 en entier, ou pour certaines d'entre elles l'utilisation aux fins de diagnostic d'une infection due à l'un des virus HIV. Ainsi le peptide <u>GAG</u> codé par le gène correspondant peut être utilisé pour repérer la présence éventuelle d'anticorps anti-HIV-1 ou anti-HIV-2. Les protéines <u>ENV</u> sont utilisées de préférence pour le diagnostic spécifique d'une infection due à HIV-2 ou un de ses variants, parfois pour le diagnostic d'une infection par HIV-2 ou HIV-1.

L'invention concerne donc également un procédé de diagnostic <u>in vitro</u> de détection d'anticorps contre HIV-2 et éventuellement contre HIV-1 dans des fluides biologiques et en particulier dans des sérums humains. De tels procédés applicables pour l'utilisation des protéines précédentes de SIV comme protéines de diagnostic, ont déjà été décrits dans la présente invention.

L'invention concerne aussi des coffrets ou "kits" pour le diagnostic <u>in vitro</u> de la présence d'anticorps le virus HIV-2 et dans certains cas contre HIV-1 dans un milieu biologique. De tels kits mettant en oeuvre les peptides précédents ont également été décrits dans la présente invention.

L'invention concerne également des compositions immunogènes pour la production de vaccins, dont le principe actif est constitué de façon avantageuse par au moins la partie de la protéine <u>ENV</u> du virus SIV, cette protéine pouvant être sous forme conjuguée avec une molécule porteuse. Ces compositions immunogènes induisent la production d'anticorps contre le susdit peptide en quantité suffisante pour inhiber les protéines du rétrovirus HIV-2, voire le rétrovirus HIV-2 lui-même.

Toutefois l'utilisation aux fins de diagnostic des protéines de SIV n'est en rien limitée à celle des seuls protéines ENV ou GAG. D'autres protéines parmi celles décrites peuvent être envisagées, pour préparer des compositions de

diagnostic voire de vaccin.

## Revendications

5

10

- 1. Séquence de nucléotides caractérisée en ce qu'elle répond à la séquence nucléotidique représentée à la figure 1B ou à la figure 1C, ou en ce qu'elle contient la séquence nucléotidique représentée à la figure 1B ou à la figure 1C, ou en ce qu'il s'agit d'une partie de la séquence représentée à la figure 1B ou à la figure 1C, ladite partie de séquence codant pour un peptide reconnu par des anticorps présents dans le sérum d'un patient infecté par un rétrovirus HIV-2 ou étant utilisable comme sonde pour la détection dans un échantillon biologique, de la présence d'un rétrovirus HIV-2.
- 2. Séquence de nucléotides selon la revendication 1, caractérisée en ce qu'elle comprend l'une des séquences suivantes identifiées dans la figure 1B ou dans la figure 1C.

1	5	

20

20

25

30

35

40

45

50

GAG s'étendant entre les nucléotides	550 à 2068
POL	1726 à 4893
Q	4826 à 5467
x	5298 à 5633
R	5637 à 5939
F	8569 à 9354
TAT-1	5788 à 6084
ART-1	6014 à 6130
TAT-2	8296 à 8391
ART-2	8294 à 8548
LTR	8950 à 9468 <u>et</u>
	1 à 316
ENV	6090 à 8732

- Séquence de nucléotides selon la revendication 1 ou la revendication 2, caractérisée en ce qu'elle comprend l'une des séquences suivantes identifiées dans la séquence de la figure 1A:
- séquence correspondant aux nucléotides 7850 à 7927
  - séquence correspondant aux nucléotides 8030 à 8095
  - séquence correspondant aux nucléotides 7601 à 7636
  - séquence correspondant aux nucléotides 6170 à 6247
  - séquence correspondant aux nucléotides 6294 à 6349
  - séquence correspondant aux nucléotides 6392 à 6445 séquence correspondant aux nucléotides 6724 à 6763
  - sequence correspondant aux nucleotides 6724 à 6763
     séquence correspondant aux nucléotides 6794 à 6838
  - séquence correspondant aux nucléotides 7112 à 7162
  - séquence correspondant aux nucléotides 7253 à 7336
  - séquence correspondant aux nucléotides 7358 à 7426
  - séquence correspondant aux nucléotides 1535 à 1597
- 4. Séquence de nucléotides caractérisée en ce qu'il s'agit d'une séquence selon la revendication 1 modifiée par dégénérescence du code génétique.
- Séquence de nucléotides selon la revendication 1, caractérisée en ce qu'il s'agit de la séquence contenue dans le plasmide pSIV-1.1 (CNCM I-658) ou dans la plasmide pSIV-1.2 (CNCM 1-659).
- 6. Séquence de nucléotides selon la revendication 1, caractérisée en ce qu'elle code pour un polypeptide choisi parmi

55

POL<sub>ROD</sub> ou POL<sub>MAC</sub> représenté à la figure 5 Q<sub>ROD</sub> ou Q<sub>MAC</sub> représentée à la figure 6 P<sub>ROD</sub> ou R<sub>MAC</sub> représentée à la figure 7

X<sub>ROD</sub> ou X<sub>MAC</sub> représentée à la figure 8 F<sub>ROD</sub> ou F<sub>MAC</sub> représentée à la figure 9 TAT<sub>ROD</sub> ou TAT<sub>MAC</sub> représentée à la figure 10 ART<sub>ROD</sub> ou ART<sub>MAC</sub> représentée à la figure 11.

5

10

20

25

30

35

40

45

- 7. Séquence de nucléotides selon l'une quelconque des revendications 1 à 6, caractérisée en ce qu'elle est marquée.
- 8. Utilisation d'une séquence de nucléotides selon l'une quelconque des revendications 1 à 7 comme sonde pour la détection dans un échantillon biologique, d'une infection par un rétrovirus HIV-2.
- Acide nucléique recombinant caractérisé en ce qu'il comprend une séquence de nucléotides selon l'une quelconque des revendications 1 à 6, insérée dans un acide nucléique provenant d'un vecteur.
- 10. Procédé de diagnostic de la présence ou non du virus HIV-2 ou d'un variant, dans des échantillons de sérums ou d'autres liquides ou tissus obtenus à partir de patients suspectés d'être porteurs du virus HIV-2 comprenant :
  - au moins une étape d'hybridation conduite dans des conditions stringentes, par mise en contact de l'ADN de cellules de l'échantillon du patient suspect avec une sonde selon la revendication 7 sur une membrane appropriée.
  - le lavage de ladite membrane avec une solution assurant la conservation de ces conditions stringentes de l'hybridation,
  - la détection de la présence ou non du virus HIV-2 par une méthode d'immunodétection.
  - 11. Procédé selon la revendication 10, caractérisé en ce que l'étape d'hybridation est conduite dans des conditions non stringentes et en ce que le lavage de ladite membrane est effectué avec une solution assurant la conservation des conditions non stringentes.

#### FIG. 1.A .

KIV2.ROD

GTCGCTCTGCGGAGAGGCTGGCAGATTGAGCCCTGGGAGGTTCTCTCCAGCACTAGCAGG TAGAGCCTGGGTGTTCCCTGCTAGACTCTCACCAGCACTTGGCCGGTGCTGGGCAGACGG RUS 100 UCCCACGCTTGCTTGCTTAAAAACCTCTTAATAAAGCTGCCAGTTAGAAGCAAGTTAAGT STGTGCTCCCATCTCTCCTAGTCGCCGCCTGGTCATTCGGTGTTCACCTGAGTAACAAGA 200 \*:CCTGGTCTGTTAGGACCCTTCTTGCTTTGGGAAACCGAGGCAGGAAAATCCCTAGCAGG TTGGCGCCTGAACAGGGACTTGAAGAAGACTGAGAAGTCTTGGAACACGGCTGAGTGAAG GCACTAAGGGCGGCAGGAACAAACCACGACGGAGTGCTCCTAGAAAGGCGCGGGCCGAGG 400 RACCAAAGGCAGCGTGTGGAGCGGGAGGAGAGACGCCTCCGGGTGAAGGTAAGTACCTA CACCAAAACTGTAGCCGAAAGGGCTTGCTATCCTACCTTACACACGCTAGAAGATTGTG 500 MetGlyAlaArgAsnSerValLeuArgGlyLysLysAlaAspSluLeuGluArgIle ArgLeuArgProGlyGlyLysLysTyrAcgLeuLysEisIleValTrpAlaAlaAsn CAGGTTACGGCCCGGCGGAAAGAAAAGTACAGGCTAAAAAATATTGTGTGGGCAGCGAA LysLeuAspArgPheGlyLeuAlaGluSerLeuLeuGluSerLysGluGlyCysGlnLys TAAATTGGACAGATTCGGATTAGCAGAGCCCTGTTGGAGTCAAAAGAGGGTTGTCAAAA 700 IleLeuThrValLeuAspProMetValProThrGlySerGluAsaLeuLysSerLeuPhe AATTCTTACAGTTTTAGATCCAATGGTACCGACAGGTTGAGAAATTTAAAAAGTCTTTT AsoThrValCysVallleTrpCyslleHisAlaGluGluLysValLysAspThrGluGlyTAATACTGTCTGCGTCATTTGGTGCATACACGCAGAAGAAAGTGAAAGATACTGAAGG 800 AlaLysGlnIle7alArgArgHisLeuValAlaGluThrGlyThrAlaGluLysHetPro **AGCAAAACAAATAGTGGGGAGACATCTAGTGGCAGAAACAGGAACTGCAGAGAAATGCC** 

FIG. 1A

	s	e	r '	T۱	ı r	S	e	r	i.	2	P	r	0	T۱	<b>.</b> 1	· A	1	اھ	Pı	r o	S	e	r	S		G	1	u I	LY		G	l v	G I	¥	A	8 T	T	y I	. P	r	0	۷۷	1	G	10	ı K	i.
,	Ā	G	Ċ.	A (	À	Ā	Ğ	T			c	c.	Ā.	A (	: A	G	Ċ.	A	2	CA	T	ċ	Ť.	Ā	20	G	À	Ġ,	۱À	G	GC	À	C	Á	A	T	T.	Ă (	c	c	A	C 1	C	C	47	LC	٨
·	_	_	-				-			-		•				_	_		-				_										-		•												
	ν		1	<b>c</b> 1	ı	c	1	u l	٠.		Ŧ	u	٠,	T I		. น	;		•	۱ ۵	P		_	1		. c		- 1	•	_	۸.	- 0	T I		1.		A	« r		. 1	۰ م	T:	- 0	v	<b>a</b> 1	l L	
-	•	-		~ /		,	ż	,,				,			, ,		•	-		l C		ċ	<u>.</u>	٠.			~	T /			r	6	ĀC		۳.	r A	A		c	:	ζ.	T		ċ	TI	ī	1
•		ı.	Λ,	•	, ,	٠		- 4	١,,			۸,	٠,	۸.			۸		•			·	6	٠.			v	٠,		1	00	`^	^		٠.		^				•	•	, ,	•	•	•••	^
						_		٠,	٠.							:								_ 1		•	_						٠,		<b>n</b> :		_	١.	. :	,		1 -		c	٠.	٠.	٠,
	ŗ	ė	u	Υį	1	6	L	ט (		u	L	y	\$	ربا	' 5	2	ם	e		y	Λ	1	2 '	6	١u	V	ā	1,	/ A	L	r		C I	y	rı	) C	Ö	10	10	. 1	8		: U		e 1		11
	T	T.	A	5 1	A	Ģ	٨	GC	À	Α	٨	A	A A	١.	C	T	T	CC	;(	; (	G	C	A	G/		G	T	A C	ï	G	CC	٨	CG	٨	1	ıı	C	A L	, 6		A	- 1		. 11	LA	. ان	٨
	_	_		_		_		• _			_					•	_				_	_		•	•						_	٠		_					•								•
																																	V a														
٨	C	C	C:	C C	C	٨	C	G	C	C	T	٨	ľ	3 /	I	٨	T	C		l C	C	A	٨	٨.	C	C	T	ľ	A	T.	T C	T	GI	.C	G	C	G.	A C	C	٨	T	CA	A	G	CA	G	С
								•					1	1	0	0									٠,														•								•
	M	e	t (	3 1	п	I	1 (	2	1	e	٨	r	2 (	3 1	u	I	1	e I	[ ]	e	A	5	n (	C 1	u	G	11	ı A	1	a	41	a	51	u	Tı	P	A	вр	٧	A	10	G 1	n	H:	i.	P	r
C																																	GA														
																	_												-			•													1 2		
	ī	1	e E	, ,	0	G	1	, p	•	0	L	• :	٠,	۰,	^	Ă	1		: 1	v	c	1	n 1	١. ۵				· C	. 1	1	,		۱T		c 1	v	s		À	•	n 1	rı					
	Ā	r.		٠,	ĭ	č	- 6	.,	ċ	č	Ξ.	T I	,		ī	ö	- /				č		- /	- 4	-		- 6	, ~		~ .			١G	2	~ ~	7	T/		~	4	Γ,	. +		ci		č	-,
•	•	• •	•	•	^		91			٠	•	1.	٠.		•		٠,	, (	•		٠.	^'	•	- 1	-	Λ,	9.		A	•	٠.			•		• ^	٠,	- 1	٠	Α,			^		••	9	•
		٠.			_	_										:		_		_				:		_						•			_		_		:					••			•
_																																	١r														
G	٨	C	١,	C	A.	۸ (	G(	۸.	C	٨	C:	ΓΑ	10	٨	٨	G	٨,	C	٨	G	٧.	T (	CC	ŀΛ	G	T	GQ	۸,					/ C	G	CC	٨	C/	۱,	٨	۷.	ĽC	: C	I	G 1	٨	Ç	C
							•	•								•								•						13									•								•
																																	; ]														
٨	G:	ľ	ľ	G	٨	٨	١c	À	T	C.	T	A I	À	G	A	A	G A	T	G	G	٨	T	C	À	G	A:	L A	G	G	A T	T	GC	À	G	۱۸	C	r	T	G	T	CA	G	G.	T A	:G	T	A
	٨ı	3 8	P	r	o'	ΓI	ı	A		n	1	l e	ı	. e	u.	A s	8 0	I	1	e	L	Y £	G	1	n (	G :	lγ	P	r	٥L	, y	s G	1	u I	'n	0 )	Pb	e	G	lı	1 S	e	r	Γy	7	74	. 1
C	A	1	c	c	Ġ	A (	20	A	Ā	c.	47	rc	c	т		c i	ίc	: 4	Ť	Ā	 A <i>i</i>		C	Ā	G	G	Á	c	c	A A	Á	GG	A	GC	:c	G:	T 1	c	Ċ.	Ā	À	Ġ	Ċ	Ă1	T	G 1	r
_		•	_	•	٠.	•		•••	••	٠.				4			••	•••	_	•		•		•••	•	•	•		٠.			_	•••	•	•		-	_	_			_	•		_		
	١.			-	. 1	٥,	. :			_ 1	٠.								_	~		١.				. 1		~	ь.	- 1		. D	r	~ 4	1	. 1	,	1	ī				<u>,</u>	t -	1	и.	
	C /	,		ċ	6.	•	, C	-	7	i i	-	,,,	3		Ϊ.		: u	•	÷	8	n.,	~ 4			•	9 1						7 E	C			4 (			-	, ,			T :	rc	۲,	4 7	: • -
	•	٠.	^	•	•	• •	. •	•	•	٠,		٠,	'n		•	• •		'n	v	٠.	٠,	-		•	^ '	-	. ~		•	10	_					•	, ,		~		•	, <b>A</b>	•		5		
	<b>-</b> 1		. ~	٠,	_ •		•		_	1			•			•			_	_				•	_ ,	n _	_			. ^		•			_			,	:		. •		_				
																																	y														
G.	A (	, (	C	Λ.	A /	ı	A	C	T	G	C 1	(A	G	T.	A (	C.	·	A	٨	T	GC	C	Α	A	C	CC	A	G	A (	T	C.	TA	A	V I	I	<b>A</b> (	ī	G	C:	T.	٨	Α.	<b>A</b> (	G	V.	C 1	Ţ
							•	_								•		_						٠								•							•							. •	
-	G 1	y	H	e	t /	۱	n	P	r	0	LF	1 T	L	ŧ	u	3	l u	G	1	u Ì	4	t	L	e	u :	ľ	ľ	A	14	ı C	y:	s G	11	n G	1	y١	74	1	G	1,	G	1	y I	Ţ	0 (	3 1	. y
A	GC	G	٨	T	G/	M	C	C	C:	I	rc	;c	Ţ	T.	A (	31	٨	G	A	G/	ľ	G	C	Ţ	G/	l C	C	G	CC	T	G:	C	A	GG	G	GC	Ţ	A	G	; I	C	G	G(	:c	A	Ç	,
																٠,								•					1	6	0(	0							•								
-	G )	D	L	y	s /	11		A:	rį	g 1	Le	u	X	e	ti	1		G	1	u į	L I	l a	L	ė	u 1	Ly	ä	G	lu	7	a i	11	10	e G	1	y I	ŗ	0.	A I	l a	P	r	o 1	1	ež	r	0
																																	T														
1	Pb	e	A	14	ı A	1		A	1 4	• (	1	n	G	1:	0.	١r	œ	L	¥	e Z	L		P	Ъ	e I	y		c.	٧.	T	rı	À	8 2	1 C	v	• G	: 1	v i	L	,,	G	11	۵ (	:1	v I	i i	
																																	Ā														
							_						ī	7	00	1			••	•		•	_	_				•	-	_				•	•	-	•		_		•	•••	•		•		•
9	S e	r	A	14	ı A	r	÷	G	1 7	. (	٠.		ī		. /	ì		P	•	n A	١.	٠.	Ā			: 1	n	n i	1 .	c		•	r	١٦.	v			- 1	2 1	9	1.		. 7		۸.	: ī	
c:	TC	Ġ	G	c i	Ä	ċ	ī	Ċ		7	ć	ċ	c	ĉ			ī	ċ	,	T.		7	Ä	ċ	2		<u>.</u>	c	-,	-	, .		G					7		• •	-	, .	•	ċ	40		Z
•		_	•		•••	•	-	٠.	••	• -		•	•	•	•	•	•	•	•	• •	• •	-	•	٠.	•		•	٠,	,,	•	•		•	-	•		•	• `	, ,	•	-	n v	,,		80		
							•				•				•	•						_		•	٠.						- 7					• •	_	_ ;					, _	_	-	-	
	, ,	_			. 14		_					_	_																				e A														
	11			re			E	I	22	- 4		D	C,	y (	ı	Ľ	0	•	8 ]	PΛ	ı	8	G	1:	17	. 1		61	l y	P	26	r	e u	Ģ	13	/ L	e	u (	; 1	y	P	ro	I	rj	ρG	1	J
A (	۸٠	Ç	Λ.	ľ	ZΔ	I	G.	A (	;	M	A	C	I	G	C	; C	Δ	G,	4.7	۲A	G	A	C	A (	G	C	A (	GG	T	T	ľ	T	TΛ	G	G/	١c	T	GC	G	Ç	C	CI	T	G	; G	G	
_			_				•								•	•								•				•			٠	,						•	•							٠	
L																																															
I	y	8	Ľ	y s	P	T	٥.	Á١	8	, A		a.	P	ь	2	T	0	٧	a 1	l A	١.	8	G	<b>1</b> 1	٧	•	11	Pz	0	G	l٥	G	1 y	L	e t	T	h	r	r	0	T	br	A	14	ıР	T	0
AA	M	C	A	A C	C	C	C	CC	C	A	A	C	T	Ţ	C	C	C	G:	r	G	C	C	C	1	G	T	T	CC	G	C/	١G	G	GĞ	C	I	A	C.	A C	c	٨	A	CA	G	CI	I C	C	
																								•					1	9(	0	1															
Pı	0	S	e :	r G	1	y	S	e s	S	e	r	\$	e:	r (	; 1	7	s	e 1	: 1	C b	r	G	1,	7 (	; 1	u	I	l e	T	y I	A	1	a A	1	a /	T	2	G 1	u	L	Y 4	ī	ъ	r (	; 1	u	
P	T	0	V	1	A	i	[ פ	Pr	٥	Á	1		V	Ì	Ā	ě	, D	Ĺ		ı L		11	c	ĺ	ī	v	• 1	۲v	· -	'n	. 2	C	lπ	C	1.	G	ĭ.	y I	. v		Á,	 . o	G	1,	٠.		ŧ
CC	C	۸	G	C	G	Ä	T	cc	Ä	c	č	Ā	c	r	c	Ā	Ť	c		Č	Ť	Č.	Ġ	Ċ	. Ā	í		,	Ť	, 1	70	C		č		ř	ċ	Ġ	í	į.	i	:1	č	ĭ	: A	č	•
	-			•	_		•	- •		. •	_	'		- 1		••	•	•			-	_							•	4		-	- 3	•		. •	•						. •			-	
Αz	P	A	1	ıc	1	υ	٠,	,	c	1	••	T	ь.	- 1	1		c	١.		: 1	*	e.	•		_	_	٠.		c	1 -	, t		, т		_ ,	•	٠,	•	_				1	.,	: 1		
ċ	1	,			i	-			. •	•	_	A 1	/ D		:		٠,		. u		7	ا جد ا	د ا د ا		-	7					, a.	-	5 A 3 T			. 1	•		۰	<b>A</b>		, 	-	1		7	
40		C.	C /			ċ	ĕ,	•	-	•	E .	<b>4</b>	. 1		-	ĭ			£			4	v 4	- 1		a:	. (	• •	u.		P	1	: U	-	5 U	H	1	, i	E	וט		U		10	<u>ن</u> ا ر	ξ.	y
ΔG		١	-2	··	•	υ,	<b>A</b> (	• 11	·	Α	9	a (	•		ï	۸	64	4	ي د	Ú	Α.	<b>A</b> I	ניי ר	4	۸	•	. (	•	Ų.	Ų.	Ü	1.7	·		ı Ç	C.	Δ(	C	I	6	- 4	١G	C	a G	Ü	v	
																		•	ı	1	8	•	1	۸٠	8	u.	LC	e	1	,																	

GlyAspThrIleGlnGlyAlaThrAsnArgGlyLeuAlaAlaProGlnPheSerLeuTrp GluThrProTyrArgGluProProThrGluAspLeuLeuHisLeuAsnSerLcuPheGly GGAGACACCATÁCAGGGAGCCACCAACAGAGGACTTGCTGCACCTCAATTCTCTCTTTTGG 2100 LysArgProValValThrAlaTyrIleGluGlyGlnProValGluValLeuLeuAspThr LysAspGln AAAAGA CCAGTAGTCACAGCATA CATTGAGGGTCAGCCAGTAGAAGTCTTGTTAGACACA GlyAlaAspAspSerIleValAlaGlyIleGluLeuGlyAsnAsnTyrSerProLysIle GGGGCTGACGACTCAATAGTAGCAGGAATAGAGTTAGGGGAACAATTATAGCCCAAAAATA 2200 ValGlyGlyIleGlyGlyPheIleAsnThrLysGluTyrLysAsnValGluIleGluVal GTAGGGGGÄATAGGGGGÄTTCATAAATACCAAGGAATATAAAAATGTAGAAATAGAAGTT LeuAsnLysLysValArgAlaThrIleHetThrGlyAspThrProIleAsnIlePheGly CTAAATAÄAAÄGGTACGĞGCCACCATAATGACAGGCGACACCCCAATGAACATTTTTGGC 2300 ArgAsnIleLeuThrAlaLeuGlyHetSerLeuAsnLeuProValAlaLysValGluPro AGAAATATTCTGACAGCCTTAGGCATGTCATTAAATCTACCAGTCGCCAAAGTAGAGCCA lleLysIleHetLeuLysProGlyLysAspGlyProLysLeuArgGlnTrpProLeuThr ATAAAAATAATGCTAAAGCCAGGGAAAGATGGACCAAAACTGAGACAATGGCCCTTAACA LysGluLysIleGluAlaLeuLysGluIleCysGluLysMetGluLysGluGlyGlnLeu AAAGAAAAATAGAAGCACTAAAAGAAATCTGTGAAAAAATGGAAAAAGAAGGECAGCTA 2500 GluGluAlaProProThrAsnProTyrAsnThrProThrPheAlaIleLysLysLysAsp GAGGAAGCACCTCCAACTAATCCTTATAATACCCCCACATTTGCAATCAAGAAAAAGGAC LysAsulysTrpArgMetLeuIleAspPheArgGluLeuAsulysValThrGluAspPhe AÄAAACAÄATGGAGGATGCTAATAGATTTCAGÄGAACTAAACAÄGGTAACTCAAGATTTC 2600 ThrGluIleGluLeuGlyIleProBisProAlaGlyLeuAlaLysLysArgArgIleThr ACAGAAATTCAGTTAGGAATTCCACACCCAGCAGGGTTGGCCAAGAAGAGAAGAATTACT 2700 ValLeuAspValGlyAspAlaTyrPheSerIleProLeuHisGluAspPheArgProTyr GTACTAGATGTAGGGGATGCTTACTTTTCCATACCACTACATGAGGACTTTAGACCATAT ThralaPheThrLeuProSerValAsnAsnAlaGluProGlyLysArgTyrIleTyrLys ACTGCATTTACTCTACCATCAGTGAACAATGCAGAACCAGGAAAAAGATACATATATAAA 2800 ValLeuProGlnGlyTrpLysGlySerProAlaIlePheGlnHisThrHetArgGlnVal GTCTTGCCACAGGGATGCAAGGGATCACCAGCAATTTTTCAACACACAATGAGACAGGTA LeuGluProPheArgLysAlaAsuLysAspValIleIleIleGluTyrMetAspAspIle TTAGAACCATTCAGAAAAGCAAACAAGGATGTCATTATCATTCAGTACATGGATGATATC 2900 LeuIleAlaSerAspArgThrAspLeuGluHisAspArgValValLeuGlnLeuLysGlu TTAATAGCTAGTGACAGGACAGATTTAGAACATGATAGGGTAGTCCTGCAGGTAAGGAA LeuLeuAsnGlyLeuGlyPheSerThrProAspGluLysPheGlnLysAspProProTyr CTTCTAAATGGCCTAGGATTTTCTACCCCAGATGAGAAGTTCCAAAAAGACCCTCCATAC HisTrpMetGlyTyrGluLeuTrpProThrLysTrpLysLeuGlnLysIleGlnLeuPro CACTGGATGGGCTATGAACTATGGCCAACTAAATGGAAGTTGCAGAAAATACAGTTGCCC 3100 GinLysGluIleTrpThrValAsnAspIleGlnLysLeuValGlyValLeuAsnTrpAla CANANAGANATATGGACAGTCAATGACATCCAGAAGCTAGTGGGTGTCCTAAATTGGGCA . (fig.lA-suite 2)

AlaGloLeuTyrProGlyIleLysTbrLysHisLeuCysArgLeuIleArgGlyLysMet GCACAACTCTACCCAGGGATAAAGACCAAACACTTATGTAGGTTAATCAGAGGAAAAATG 3200 ThrLeuThrGluGluValGlnTrpThrGluLeuAlaGluAlaGluLeuGluGluAsnArg ACACTCACAGAAGAAGTACAGTGGACAGAATTAGCAGAAGCAGAGCTAGAAGAAAACAGA IleIleLeuSerGlnGluGlnGluGlyEisTyrTyrGlnGluGluLysGluLeuGluAls ATTATCCTAAGCCAGGAACAAGAGGGACACTATTACCAAGAAGAAAAAAAGAGCTAGAAGCA ThrValClnLysAspGluGluAsnGluTrpThrTyrLysIleHisGlnGluGluLysIle AGAGTCCAAAAGGATCAAGAGAATGAGTGGACATATAAAATACACCAGGAAGAAAAATT Leulys ValGlyLysTyrAlsLysValLysAsnThrHisThrAsnGlyIleArgLeuLeu CTANAAGTAGGAAAATATGCAAAGGTGAAAAACACCCATACCAATGGAATCAGATTGTTA AlaGlnValValGlnLyslleGlyLysGluAlaLeuValIleTrpGlyArgIleProLys GCACAGGTAGTTCAGAAATAGGAAAAGAAGCACTAGTCATTTGGGGACGAATACCAAAA 3500 PheHisLeuProValGluArgGluIleTrpGluGlnTrpTrpAspAsnTyrTrpGlnVal TTTCACCTACCAGTAGAGAGAGAATCTGGGAGCAGTGGTGGGATAACTACTGGCAAGTG 3600 Thr Trp I le Pro Asp Trp Asp Phe Val Ser Thr Pro Pro Leu Val Arg Leu Ala Phe Asn ACATGGATCCCAGACTGGGACTTCGTGTCTACCCCACCACTGGTCAGGTTAGCGTTTAAC LeuValGlyAspProIleProGlyAlaGluThrPheTyrThrAspGlySerCysAsnArg CTGGTAGGGGATCCTATACCAGGTGCAGAGACCTTCTACACAGATGGATCCTGCAATAGG 3700 GlmSerLysGluGlyLysAlaGlyTyrValThrAspArgGlyLysAspLysValLysLys CAATCAAAAGAAGGAAAAGCAGGATATGTAACAGATAGAGGGAAAGACAAGGTAAAGAAA LeuGluGlnThrThrAsnGlnGlnAlaGluLeuGluAlaPheAlaMetAlaLeuThrAsp CTAGAGCAAACTACCAATCAGCAAGCAGAACTAGAAGCCTTTGCGATGGCACTAACAGAC SerGlyProLysValAsmIleIleValAspSerGinTyrValMetGlyIleSerAlaSer TCGGGTCCAAAAGTTAATATTATAGTAGACTCACAGTATGTAATGGGGATCAGTGCAAGC GinProThrGluSerGluSerLysIleValAsnGlnIleIleGluGluMetIleLysLys CAACCAACAGAGTCAGAAAGTAAAATAGTGAACCAGATCATAGAAGAAATGATAAAAAAG GluAlaIleTyrValAlaTrpValProAlaBiaLysGlyIleGlyGlyAsnGlnGluVal GAAGCAATCTATGTTGCATGGGTCCCAGCCCACAAAGGCATAGGGGGAAACCAGGAAGTA 4000 AspHisLeuValSerGlnGlyIleArgGlnValLeuPheLeuGluLysIleGluProAla GATCATTIAGTGAGTCAGGGTATCAGACAAGTGTTGTTCCTGGAAAAAATAGAGCCCGCT GlnGluGluHisGluLysTyrHisSerAsnValLysGluLeuSerHisLysPheGlyIle CAGGAAGAACATGAAAAATATCATAGCAATGTAAAAGAACTGTCTCATAAATTTGGAATA ProAsnLeuVslAlsArgGlnIleVslAsnSerCysAlsGlnCysGlnGlnLysGlyGlu CCCAATTTAGTGGCAAGGCAAATAGTAAACTCATCTGCCCAATGTCAACAGAAAGGGGAA 4200 AlaIleHieGlyGlnValAsnAlaGluLeuGlyThrTrpGlnHetAspCysThrWisLeu GCTATACATGGGCAAGTAAATGCAGAACTAGGCACTTGGCAAATGGACTGCACACATTTA GluGlyLyaIleIleIleValAlaValHieValAlaSerGlyPheIleGluAlaGluVal GAAGGAAAGATCATTATAGTAGCAGTACATGTTGCAAGTGGATTTATAGAAGCAGAAGTC 4300 IleProGlnGluSerGlyArgGlnThrAlaLeuPheLeuLeuLysLeuAlaSerArgTrp ATCCCACAGGAATCAGGAAGACAACAGCACTCTTCCTATTGAAACTGGCAAGTAGGTGG

ProlleThrHisLeuHisThrAspAsnGlyAlsAsnPheThrSerGlnGluValDysHet CCAATAACACACTTGCATACAGATAATGGTGCCAACTTCACTTCACAGGAGGTGAAGATG 4400 ValAlaTrpTrpIleGlyIleGluGlnSerPheGlyValProTyrAsnProGlnSerGln GTA GCATGGTGGATAGGTATAGAACAATCCTTTGGAGTACCTTACAATCCACAGAGCCAA GlyValValGluAlaHetAsnHisHisLeuLysAsnGlnTleSerGluThrTleValLeu GGAGTAGTAGAAGCAATGAATCACCATCTAAAAAACCAAATAAGTGAAACAATAGTACTA  ${\tt MetAlaIleHisCysMetAsnPheLysArgArgGlyGlyIleGlyAspMetThrProSer}$ ATGGCAATTCATTCCATGAATTTTAAAAGAAGGGGGGGAATAGGGGATATGACTCCATCA 4600 GluArgLeuIleAsnMetIleThrThrGluGlnGluIleGlnPheLeuGlnAlaLysAsn GAAAGATTAATCAATATGATCACCACAGAACAAGAGATACAATTCCTCCAAGCCAAAAAT SerLysLeuLysAspPheArgValTyrPheArgGluGlyArgAspGlnLeuTrpLysGly TCAAAATTAAAAGATTTTCGGGTCTATTTCAGAGAAGGCAGAGATCAGTTGTGGAAAGGA 4700 ProGlyGluLeuLeuTrpLysGlyGluGlyAlaValLeuValLysValGlyThrAspIle CCTGGGGAACTACTGTGGAAAGGAGAAGGAGCAGTCCTAGTCAAGGTAGGAACAGACATA Lys I le I le Pro Argarg Lys Ala Lys I le I le Argas p Tyr Gly Gly Arg Glo Glu Het MetGluGluAspLysArgTrp A A A TA A TA CC A A GA A GGA A GC CA A GA T CA TC A GA GA CTA T GGA GGA A GA CA À GA GÀ T G AspSerGlySerRisLeuGluGlyAlaArgGluAspGlyGluMetAla IleValValProThrTrpArgValProGlyArgMetGluLysTrpHisSerLeuValLys GATAGTGGTTCCCACCTGGAGGGTGCCAGGGAGGATGGAGAAATGGCATAGCCTTGTCAA TyrLeuLysTyrLysThrLysAspLeuGluLysValCysTyrValProHisHisLysVal GTATCTAAAATACAAAACAAAGGATCTAGAAAAGGTGTGCTATGTTCCCCACCATAAGGT GlyTrpAlaTrpTrpThrCysSerArgValllePheProLeuLysGlyAsnSerHisLeu GGGÁTGGGCATGGTGGACTTGCAGCAGGGTAATATTCCCATTAAÁAGGÁAACAGTCATCT 5000 GluIleGinAlaTyrTrpAsnLeuThrProGluLysGlyTrpLeuSerSerTyrSerVal AGAGATACAGGCATATTGGAACTTAACACCAGAAAAAGGATGGCTCTCCTCTTATTCAGT ArgIleThrTrpTyrThrGluLysPheTrpThrAspValThrProAspCysAlsAspVal AAGAATAACTTGGTACACAGAAAAGTTCTGGACAGATGTTACCCCAGACTGTGCAGATGT LeuIleHisSerThrTyrPheProCysPheThrAlaGlyGluValArgArgAlaIleArg CCTAATACATAGCACTTATTTCCCTTGCTTTACAGCAGGTGAAGTAAGAAGAGCCATCAG 5200 GlyGluLysLeuLeuSerCysCysAsnTyrProArgAlaHisArgAlaGlnValProSer AGGGGAAAAGTTATTGTCCTGCTGCAATTATCCCCGAGCTCATAGAGCCCCAGGTACCGTC LeuGlnPheLeuAlaLeuValValValGlnGlnAsnAspArgProGlnArgAspSerThr MatThrAspProArgGluThrValPro ACTICAATITCTGGCCTTAGTGGTAGTGCAACAAAATGACAGACCCCAGAGAGACAGTAC 5300 ThrangLysGlnArgArgAspTyrArgArgGlyLeuArgLeuAlaLysGlnAspSer ProGlyAsnSerGlyGluGluThrIleGlyGluAlaPheAlaTrpLeuAsnArgThrVal CACCAGGAAACAGCGGCGAAGAGACTATCGGAGAGGCCTTCGCCTGGCTAAACAGGACAG Arg SerHisLysGlmArg SerSerGluSerProThrProArgThrTyrPheProGlyVal GluAlaIleAsnArgGluAlaValAsnHisLeuProArgGluLeuIlePheGlnValTrp TAGAAGCCATAAACAGAGAAGCAGTGAATCACCTACCCCGAGAACTTATTTTCCAGGTGT (fig.la-suite 4)

```
AlaGlu ValLeuGlu IleLeuAla
  GlnArgSerTrpArgTyrTrpHisAspGluGlnGlyHetSerGluSerTyrThrLysTyr
 GGCAGAGĞTCCTGĞAGĂTÁCTGĞCATGATGAACAAGGĞATGTCAGAAAGTTACACAAAGT
                                    5500
   ArgTyrLeuCysIleIleGlnLysAlaValTyrMetHisValArgLysGlyCysThrCys
LeuGlyArgGlyBisGlyProGlyGlyTrpArgProGlyProProProProProProPro
GCCTGGGGAGGGGACATGGGCCAGGAGGGTGGAGACCAGGGCCTCCTCCTCCTCCCCCTC
                5600
             MetAlaGluAlaProThrGluLeuProProValAspGlyThrProLeu
  GlyLeuVal***
CAGGTCTGGTCTAATGGCTGAAGCACCAACAGAGCTCCCCCGGTGGATGGGACCCCACT
 ArgGluProGlyAspGluTrpIleIleGluIleLeuArgGluIleLysGluGluAlaLeu
GAGGGAGCCAGGGGATGAGTGGATAATAGAAATCTTGAGAGAAATAAAAGAAGAAGCTTT
 Lys His Phe AspProArgLeuLeuIleAlaLeuGlyLysTyrIleTyrThrArgHisGly
                                                       MetGlu
AAAGCATTTTGACCCTCGCTTGCTAATTGCTCTTGGCAAATATATCTATACTAGACATGG
                                    5'8'00
 AspThrLeuGluGlyAlaArgGluLeuIleLysValLeuGlnArgAlaLeuPheThrHis
  ThrProLeuLysAlaProGluSerSerLeuLysSerCysAsnGluProPheSerArgThr
AGACACCCTTGAAGGCGCCAGAGAGCTCATTAAAGTCCTGCAACGAGCCCTTTTCACCCA
 PheArgAlaGlyCysGlyHisSerArgIleGlyGlnThrArgGlyGlyAsnProLeuSer
  SerGluGlnAspValAlaThrGlnGluLeuAlaArgGlnGlyGluGluIleLeuSerGln
CITCAGAGCAGGATGTGGCCACTCAAGAATTGGCCAGACAAGGGGAGGAAATCCTCTCTC
                5900
 AlaIleProThrProArgAsnMetGlm
  LeuTyrArgProLeuGluThrCysAsuAsuSerCysTyrCysLysArgCysCysTyrHis
AGCTATACCGACCCCTAGAAACATGCAATAACTCATGCTATTGTAAGCGATGCTGCTACC
                                         MetAsnGluArgAlaAsp
  CysGlnHetCysPheLeuAsnLysGlyLeuGlyIleCysTyrGluArgLysGlyArgArg
ATTGTCAGATGTGTTTTCTAAACAAGGGGCTCGGGATATGTTATGAACGAAAGGGCAGĀC
GluGluGlyLeuGlnArgLysLeuArgLeuIleArgLeuLeuHisGlnThrSerGluTyr
  ArgArgThrProLysLysThrLysThrHisProSerProThrProAspLys
GAA GAAGGACTCCAAAGAAAACTAAGACTCATCCGTCTCCTACACCAGACAAGTGAGTAT
                                   6100
AspGluSerAlsAlaTyrCysHisPhelleSer
MetAsnGlnLeuLeuIleAlaIleLeuLeuAlaSerAlaCysLeuValTyrCysThrGln
GATGAATCAGCIGCITATIGCCATITIATIAGCIAGIGCTIGCTAGTATATIGCACCCA
 TyrValThrValPheTyrGlyValProThrTrpLysAsnAlaThrIleProLeuPheCys
ATATGTAACTGTTTTCTATGGCGTACCCACGTGGAAAAATGCAACCATTCCCCTCTTTTG
               6200
 AlaThrArgAsnArgAspThrTrpGlyThrIleGlnCysLeuProAspAsuAspAspTyr
TGCAACCAGAAATAGGGATACTTGGGGAACCATACAGTGCTTGCCTGACAATGATGATTA
 GlnGluIleThrLeuAsnValThrGluAlaPheAspAlaTrpAsnAsnThrValThrGlu
TCAGGAAATAACTTTGAATGTAACAGAGGCTTTTGATGCATGGAATAATACAGTAACAGA
GluAlsIleGluAspValTrpHisLeuPheGluThrSerlleLysProCysValLysLeu
ACAAGCAATAGAAGATGTCTGGCATCTATTCGAGACATCAATAAAACCATGTGTCAAACT
                                   6400
                  *(fig.lA-sufte 5)
```

ThrProLeuCysValAlaMetLysCysSerSerThrGluSerSerThrGlyAsnAsnThr AACACCTTTATGTGTAGCAATGAAATGCAGCAGCACAGAGAGCAGCACAGGGAACAACAC Thr Serlys SerThr SerThr Thr Thr Thr Thr Thr Pro Thr Asp GluGluGluGluIle Ser AACCTCAAAGAGCACAAGCACAACCACACCACACCACAGACCAGGAGCAAGAGATAAG 6500 GluAspThrProCysAlaArgAlaAspAsnCysSerGlyLeuGlyGluGluGluThrIle TGA GGATACTCCATGCGCACGCGCAGACAACTGCTCAGGATTGGGAGAGGAAGAAA CGAT As nCysGloPheAsoHetThrGlyLeuGluArgAspLysLysGlnTyrAsnGluThr CAATTGCCAGTTCAATATGACAGGATTAGAAAGAGATAAGAAAAAACAGTATAATGAAAC TrpTyrSerLysAspValValCysGluThrAsnAsnSerThrAsnGlnThrGlnCysTyr ATGGTACTCAAAAGATGTGGTTTGTGAGACAAATAATAGCACAAATCAGACCCAGTGTTA MetAsnHisCysAsnThrSerVallleThrGluSerCysAspLysHisTyrTrpAspAla CATGAACCATTĞCAACACATCAGTCATCACAGAATCATĞTGACAAGCACTATTGGGATGC IleArgPheArgTyrCysAlaProProGlyTyrAlaLeuLeuArgCysAsnAspThrAsn TATAAGGTTTAGATACTGTGCACCACCGGGTTATGCCCTATTAAGATGTAATGATACCAA 6800 TyrSerGlyPheAlaProAsnCysSerLysValValAlaSerThrCysThrArgNetHet TTATTCAGGCTTTGCACCCAACTGTTCTAAAGTAGTAGCTTCTACATGCACCAGGATGAT GluThrGlnThrSerThrTrpPheGlyPheAsnGlyThrArgAlaGluAsnArgThrTyr GGAAACGCAAACTICCACATGGTTTGGCTTTAATGGCACTAGAGCAGAGAATAGAACATA IleTyrTrpHisGlyArgAspAsnArgThrIleIleSerLeuAsnLyeTyrTyrAsnLeu TATCTATTGGCATGGCAGAGATAATAGAACTATCATCAGCTTAAACAAATATTATAATCT 7000 SerLeuRisCysLysArgProGlyAsnLysThrValLysGlnIleHetLeuMetSerGly CAGTITGCATTGTAAGAGGCCAGGGAATAAGACAGTGAAACAAATAATGCTTATGTCAGG His ValPheHis Ser His Tyr Gln Prolle Asn Lys Arg Pro Arg Gln Ala Trp CysTrp ACATGTGTTTCACTCCCACTACCAGCCGATCAATAAAAGACCCAGACAAGCATGGTGCTG 7100 PheLysGlyLysTrpLysAspAlaMetGlnGluValLysGluThrLeuAlaLysHisPro GTTCAAAGGCAAATGGAAAGACGCCATGCAGGAGGTGAAGGAAACCCTTGCAAAACATCC ArgTyrArgGlyTbrAsuAspTbrArgAsnIleSerPbeAlaAlaProGlyLysGlySer CAGGTATAGAGGAACCAATGACACAAGGAATATTAGCTTTGCAGCGCCAGGAAAAGGCTC AspProGluValAlaTyrHetTrpThrAsnCysArgGlyGluPheLeuTyrCysAsnHet AGA CCCAGAAGTAGCATACATGTGGACTAACTGCAGAGGAGAGTTTCTCTACTGCAACAT 7300 ThrTrpPheLeuAsnTrpIleGluAsnLysThrHisArgAsnTyrAlaProCysHisIle GACTTGGTTCCTCAATTGGATAGAGAATAAGACACCCCCAATTATGCACCGTGCCATAT LysGlnIleIleAsnThrTrpHisLysValGlyArgAsnValTyrLeuProProArgGlu AAAGCAAATAATTAACACATGGCATAAGGTAGGGAGAAATGTATATTTGCCTCCCAGGGA 7400 GlyGluLeuSerCysAsnSerThrValThrSerIleIleAlsAsnIleAspTrpGlnAsn AGGGGAGCTGTCCTGCAACTCAACAGTAACCAGCATAATTGCTAACATTGACTGGCAAAA AsuAsuGluThrAsuIleThrPheSerAlaGluValAlaGluLeuTyrArgLeuGluLeu CAATAATCAGACAAACATTACCTTTAGTGCAGAGGTGGCAGAACTATACAGATTGGAGTT GlyAspTyrLysLeuValGluIleThrProIleGlyPheAleProThrLysGluLysArg 7600 (fig.lA-suite 6)

TyrSerSerAlaBisGlyArgBisTbrArgGlyValPheValLeuGlyPheLeuGlyPhe ATACTCCTCTCCTCACGGAGACATACAAGAGGTGTGTTCGTGCTAGGGTTCTTGGGTTT LeuAlaThrAlaGlySerAlaMetGlyAlaAlaSerLeuThrValSerAlaGluSerArg TCTCGCAACAGCAGGTTCTGCAATGGGCGCGGCGTCCCTGACCGTGTCGGCTCAGTCCCG 7700 ThrLeuLeuAlaGlyIleValGlnGlnGlnGlnLeuLeuAspValValLysArgGln GACTTTACTGGCCGGGATAGTGCAGCAACAGCAACAGCTGTTGGACGTGGTCAAGAGACA 7800 GinGluLeuLeuArgLeuThrValTrpGlyThrLysAsnLeuGlnAlaArgValThrAla ACAAGAACTGTTGCGACTGACCGTCTGGGGAACGAAAAACCTCCAGGCAAGAGTCACTGC IleGluLysTyrLeuGlnAspGlnAlsArgLeuAsnSerTrpGlyCysAlsPheArgGln TATAGAGAAGTACCTACAGGACCAGGCGCGGCTAAATTCATGGGGATGTGCGTTTAGACA ValCysHisThrThrValFroTrpValAsnAspSerLeuAlsProAspTrpAspAsnHet AGT CTGCCACACTACTGTACCATGGGTTAATGATTCCTTAGCACCTGACTGGGACAATAT ThrTrpGlnGluTrpGluLysGlnValArgTyrLeuGluAlaAsnIleSerLysSerLeu CACCTCGCAGGAATGGGAAAAACAAGTCGGCTAGGTGGAGGCAAATATCAGTAAAAGTTT 8000 GluGlnAlaGlnIleGlnGlnGluLysAsnHetTyrGluLeuGlnLysLeuAsnSerTrp AGAACAGGCACAAATTCAGCAAGAGAAAATATGTATGAACTACAAAAATTAAATAGCTG 8100 AspIlePheGlyAsnTrpPheAspLeuThrSerTrpValLysTyrIleGlnTyrGlyVal GGATATTTTTGGCAATTGGTTTGACTTAACCTCCTGGGTCAAGTATATTCAATATGGAGT LeuIleIleValAlaValIleAlaLeuArgIleValIleTyrValValGlpMetLeuSer **GCTTATAATAGTAGCAGTAATAGCTTTAAGAATAGTGATATATGTAGTACAAATGTTAAG** 8200 AlaCysPheLeuPheProProArgLeuTyrProThrAsp ArgLeuArgLysGlyTyrArgProValPheSerSerProProGlyTyrIleGlnGlnIle GlyLeuGluArgAlaIleGlyLeuPheSerLeuProProProVallleSerAsnArgSer ProTyrProGlmGlyProGlyThrAlaSerGlmArgArgAsmArgArgArgArgTrpLys BisIleHisLysAspArgGlyGluProAlsAsuGluGluThrGluGluAspGlyGlySer IleSerThrArgThrGlyAspSerGlnProThrLysLysGlnLysLysThrValGluAla 8300 GlnArgTrpArgGlnIleLeuAlaLeuAlaAspSerIleTyrThrPheProAspProPro AsnGlyGlyAspArgTyrTrpProTrpProIleAlaTyrIleHisPheLeuIleArgGln ThrValGluThrAspThrGlyProGlyArg CAACGGTGGAGACAGATACTGGCCCTGGCCGATAGCATATATACATTTCCTGATCCGCCA RAAA AlsAspSerProLeuAspGlnThrIleGlnBisLeuGlnGlyLeuThrIleGlnGluLeu LeulleArgLeuLeuThrArgLeuTyrSerIleCysArgAspleuLeuSerArgSerPhe GCTGATTCGCCTCTTGACCAGACTATACAGCATCTGCAGGGACTTACTATCCAGGAGCTT ProAspProProThrHisLeuProGluSerGlnArgLeuAlaGluThr LeuThrLeuGlnLeuIleTyrGlnAsnLeuArgAspTrpLeuArgLeuArgThrAlsPhe CCTGACCCTCCAACTCATCTACCAGAATCTCAGAGACTGGCTGAGACTTAGAACAGCCTT 8500 LeuGluTyrGlyCysGluTrpIleGluGluAlaPheGluAlaAlaAlaArgAlaThrArg HetGlyAlaSerGlySerLysLysBisSerArgProProArgGlyLeuGlnGlu CITGCAATATGGGTGCGAGTGGATCCAAGAAGCATTCCAGGCCGCCGCGAGGGCTACAAG (fig.lA-suite 7)

						•							٠							•	•						•	•						•							•	
(	;1,	Ţ	P	r I		บ	A I	ı	G	13	y A	14	ı C	y i	ı۸	r	g (	; 1	y	L	u	Ī	гp	٨	rg	٧	a l	L	e u	Ç	lu	ıA	rį	ξI	1	e G	1	y i	١r	g C	1	y
	A :	C 22	L	e١	ıL	e	u /	١r	2	A :	ì a	٨ı	2	A:	la	G	11	٠A	14	• (	, A	s (	; 1	y	G 1	y	T 5	T	T :	P.	Aε	מ	G :	lυ	S	e I	C	1	y G	l y	G	lu
AC	A	Ä	C	T	: 1	T	GC	: G	Ğ	G	CG	CC	Ť	G	:A	G	GÖ	G	C	7	Ğ	7(	GG	À	GG	G	TĂ	T	TG	Ğ,	AA	C	G/	٨	T	CG	C	G.	C	GC	C	
		•••	•	-		-	-		•	•	Ř	60	0														_															
1	11	١.			1	:	٧.	. 1	p	- 1	Ā	*	ī	* (	, T	1	. 1		0 (	•	l n	G :	ו ע	A	1 4	G	1 11	7	1 4	A	۱.	L	e ı	ıL	e	u						
•	4.	- L	5			-	- 1		•		, <u> </u>	~ 1	,	^!		ė	••		<b>b</b> `			~ (	• /	••	c 1	_			ė	'		_	ς,		C	-	c	١.	۰.	1 4	A	r g
	43	7 [	ر -	e 1		I.	g		=	6		6.	LU	٠.	y	3	E I			,	L I	8,	,,	u ·			د .		3 E			0			Ξ,	, . 	~			- 1	Ç	• 6
٨٨	T	C	T	C	C	G	G 1	I	C	C	۱,	G A	W	GC	۸	T	CA	G	A (		G	G	įΑ	G	CA	G	AA	A	1 0	G		C	1 (	٠.	1,	6 1	U	۸,				
						•							•							•	•						•							•		_	_		_	70	_	_
	G I	م ا	T;	y z	G	1	۵G	: 1	ם ו	G 1	l y	۸ı	P	Pì	) e	H	e t	<b>.</b> A	8 1	17	(h	rI	ŗ	0	Tı	P.	Ly	8 4	A s	P)	Pz	0	A I	3	A.	l a	G	lυ	ı A	r g	G	lu
GG	CA	G	T	١1	C	A	GC	A	G	GG	À	GA	C	T	T	۸	TC	À	A7	î A	C.	r	:c	۸	TG	G	۸۸	G	GA	C	CC	A	GC	À	G	CA	C	٨A	A	C C	G	
																					,																					
	L		<b>.</b>	B 17	L	ė	u T		T	Å T		G 1	ח	<b>G</b> 1	n	Ā	6 D	M	e t	: A	L B 1	οA		ים	V a	14	A s	D S	S e	r i	۱.	D.	A s	D	٨ı	B D	٨	8 P	G	ם נ	V	<b>a</b> 1
AG	- 1	ī	4	. 7	<u> </u>	T			ċ		ĉ	~ .	4	, ,		1	4 7		TC			7.0	: A	5 T (				T .	rc	A	: 4	T	. A	Ť	C.I	Ť	c	ÀC	Ċ	AA	c	
Α.	ne		~	••	•	•			٠,		•	U.A		V A	. ~			A		, ,		• •	,,	• •		•	•		• •	•	,,	•	9 2	•	•	• •	•				•	
						•								,							•						0			٠				•	•						٠	
	A	rg	٧:	4	1:	S e	T	٧a	a 1	T	þ i	P	T O	L	y i	s V	4	11	, L	0	Le	u.	۸ı	2	P	ro	H	e t	TI	ır	H:	i s	A	rg	L	eu	١A	.1	a I	1	٠A	8 5
T	۸۸																																									
																																		•								
	м	e t	S	•	<b>r</b> 1	4 ;		t. 4	- 11	T	١,	1.	ve	T	h i	- 4		. G	: 1	v	Ġ١	v	١. ه		G 1	١.,	c i	יי	M a		P)		T.		. s		·G	1.	1 A	т.	À	T g
	TΑ	70	· T	ř	Δ.	- 4	T	Ti		1	Ť.	<u> </u>	, -	Ā	~ /	Ä	2	6.0	ċ	, ,	cc	1		-	ci		c		4 1	Ġ	- ·	7	÷			61				Ĝ		
•	'n		•	•		<b>,</b>	•	• 4	. ^	^			n 4		•			•			30	n,	<b>.</b> 1	•	O F	ın	٠,	, ,	Λ.				- 4			<b>.</b>	. •		'n	•		
	••					.:					•	יכי	•	_				_			•						_ :		٠.		٠.			. •			_			• -	:	
_																																										8 17
G.	AC.	A I	Α	٨	A A	lΤ	C	Γ7	A	A	A I	A	ΓA	T	4	T	T	A G	A	٨	۱A	G	GA	A	G A	A	GC	G.	A T	A.	٨1	T	G (	١,	G	A I	Ţ	G				
						٠							•							•	•													•					-	00	-	
	T	y I	T	h	rł	li		3 1	y	P	ro	G	l y	٧.	a 1	A	rş	Ţ	y i	r I	) r	o l	He	t	Pb	e	Pb	e	G 1	y'	T	P	Le	e u	T	r p	L	y s	L	e u	٧	<b>s</b> 1
A	CT.																																									
													_											_		•				•		•	-	_	•			•••				
	p.	- ^	v		۱ 4		۰,	,	1	ъ,		G		c	١.,	c	١,	٠.	١.			n 1	T h	-1	c 1		Th	-	a :	-1	٠.		t. a		v .	- 1	H		ъ.	<b>.</b> .	Ă	1 .
т.	LC		ċ	<b>-</b>		Ĭ	r T/		,	ci	• •	~		-		~	~ 7	. ,		• •	•	r	. ~	•	~ .	~	•		~ 4		-		- T				7			~ ~	~	-
٠.		<b>.</b> .		••	•	•	٠,	•	•	٠,		C.	•••	0,	3.01	. •	•		۰,	,		••	•	• '			00			<b>.</b>		·			<b>G</b> .	LA	•			- A	u	
	_	٠	_	٠.	_	•				٠.			•			_				. :									_		_			•					_		:	
_	د	10	. 1	ום		e	Li	· y		<i>r</i> !	9 6	A	P	A	P	r	rc	) E	11	5 4	١.	y	<i>i</i> 1	u :	ם		Le	u '	V A	11	ľ	P	<u>ا</u> ا	u	PI	3 e	٨	e p		10	L	eu
Ç	C	۸۸	A	C		G	C	۱۸	G	T	T	G.	\T	G/	١c	Ç	CC	C	A I	rc	G	GC	ŀΛ	G/	A C	A	CI	A	G T	C:	r G	G	5 A	G	T	CI	G.	A I	C	CC	I	
						٠							•							•	•						•							•							•	
	L	t u	A	14	1	y	r	e	r	T۱	ľ	G 1	lu.	A I	l a	P	h e	I	1 6	٠A	T	3	Ìу	r I	Pr	0(	5 1	u (	; 1	u I	, Р	e(	; 1	y	H i		L	y s	S	e T	G :	l y
TO	C	۲G	G	C 1	T	¥,	TA	G	T	T.	C	GA	G	G	Ì	T	TI	A	TI	C	G	G I	A	C	C	A	3 A	G	3 A	A1	T	T	G	G	CA	C.	A	ĀG	T	A:	G	-
												20															•												_			
	L	e u	P	rc	G	1	u G	1	u	G 1	ı.	Tı	מ	L	, .	A	1 .	A	ra	Ł		ı I	. v	. /	l I		١·	• 0	2 1	v 1	1	•1	,	Ď	Pŀ		2				•	
GC	C	T G	C	CA	G	Ā	GG	À	Ă	GA	G	TO		 A A	Ġ	G	cc	A	ā	ď	T	: 4	Ĭ.	4 6	ċ	A 4	īc	Ā	20	, - A A	Ť	Ă (		Ĭ.	77	· •	A (	. T	Ŧ /		4	
		-	_		-	_	-	•••	•••	-	••		-		. •	•	•	_	•		•						••				•	•		-	• •	•	•	• 1		30		
GA	CA	c	c		_						_	~~	•	~ =			~ ~	_	۰.	:			_			_	•			٠.				•								
V.		. •	0,	44	. •	A.		•	Α.			1 1	G	נ ט		A I		U	CA	. 6	61	M	6	1.	·v	C	LA	Δι	٨	64	IA.	Λ(	٨	Ģ	CI	G	A (	۸٠	C 7	r G	C	
					_	•		_					•					_		•			_				•		_					٠							٠	
AG	G	i٨	C	LI	Ί	C	CA	G	A	I C	G	GG	C.	TC	Ι	A	V C	C	٨A	G	G	įλ	G	GG				GG	G.	AG	G.	AG	C	T	GG	T	G	G	G١	M	C	
						•							•	۲,						•							0				٠										•	
GC	CC	I	C	ľ	Α	T	rc	T	C	r G	T	AT	A	AA	T	٨	ΓA	C	CC	G	CI	A7	G	CI	T	GC	A	TI	G.	TA	C	TI	C	G	GI	C	GC	T	C1	G	C	
GG	AC	A	G	30	T	G	GC	A	G/	LI	T	GA	G	CC	C	T	G	G	A G	G	TI	C	T	7	C	C.A	G	CA	G	T.A	G	C.A	G	Ğ٦	r.	G	L C	c	C1	:G	3	
٠.												50															_				_		-			_				- '	_	
GI	CT																						· ·	-	-	00		00	_		^	. ^	_	• •		~ .		~		- 1	-	
~ I	- 1	•	- 1		•	•	•	**	J /			o I	<b>U</b> 1	A C	•	Δ(		<b>~</b> (	o I	1	v	٠.	<u> </u>			. C		•	v	<u>۸</u>	U.	ı, U	U	<b>u</b> (	ن .	<b>(</b>	- 4					
			٠.			•.			<b>.</b>			~ <del>~</del>	•		_			_	. –	•							٠							•					ס צ	0 (	•	
GC								-			471		-		T			ce	- 7	•	rr	- 4					4 (															

(fig.lA-suite 8)

# FIG 1B

AGTCGCTCTGCGGAGAGGCTGGCAGATTGAGCCCTTGGAGGTTCTCTCCAGCACTAGCAG GTAGAGCCTGGGTGTTCCCTGCTAGACTCTCACCAGCACTTGGCCGGTGCTGGGCAGAGT GGCTCCACGCTTGCTTAAAGACCTCTTCAATAAAGCTGCCATTTAGAAGTAAGCTA GTGTGTGTTCCCATCTCCTAGTCGCCGCCTGGTCAACTCGGTACTCGGTAATAAAAAG ACCCTGGTCTGTTACGACCCTGGTCTGTTAGGACCCTTTCTGCTTTGGGAAACCGAAGCA 300 GGAAAAT CCCT AGCAGAT TGGCGCCCG AACAGGGACTTGAAGGAGAGT GAGAGACTCCTG 400 CAGGTAAGTGCAACACAAAAAGGAAATAGCTGTCTTTTATCCAGGAAGGGATAATAAGAT 500 GA G DHET GLY AL AARGASN SERVALLEUSERGLYLYSLYSAL AA SPGLULEUGLU AGAGTGGGAGATGGGCGGGAGAACTCCGTCTTGTCAGGGAAGAAGCAGATGAATTAGA LYS ILEARĞLEUAR GPROĞLYGLYLYSL YSLYSTYRMETLEULYSHI SVAL YALTRPALA AAAAATTAGACTACGACCCGGCGGAAAGAAAAAGTACATGTTGAAGCATGTAGTATGGGC ALAASNGLULEUASPAR GPHEGLYLEUALAGLUSERLEULEUGLUASNLYSGLUGLYCYS AGCA AAT GAAT TAGAT AGAT TEGAT TAGCAGAAGCCTGTTGGAGAACAAAGAAGGATG GLNLY SILELEUSERVALLEUAL A PROLEUVAL PROTHRGLY SERGL UA SNLEULY SSER TCAAAAAATACTTTCGGTCTTAGCTCCATTAGTGCCAACAGGCTCAGAAAATTTAAAAAG LEUTYRASNTHRVALCYSVAL IL ETRPCYS ILEHI SALAGLUGLULYSVALLYSHI STHR CCTTTATAATACTGTCTGCGTCATCTGGTGCATTCACGCAGAAGAGAAAGTGAAACACAC 800 GLUGLUALALYSGLNILEVAL GLNARGHISLEUVALHETGLUTHRGLYTHRALAGLUTHR TGAGGAAGCAAAACAGATAGTGCAGAGACACCTAGTGATGGAAACAGGAACAGCAGAAAC MET PROLYŠTHRSERAR GPROTHRALA PROPHE SERGLÝAR GGLYGLYÁS NT YR PROVAL TATGCCAAAAACAAGTAGACCAACAGCACCATTTAGCGGCAGAGGAGGAAATTACCCAGT GLNGLNILEGLYGLYASNTYRTHRHISLEUPROLEUSERPROARGTHRLEUASHALATRP ACAACAAATAGGTGGTAACTATACCCACCTACCATTAAGCCCGAGAACATTAAATGCCTG VALLY SLEU I LE GLUGLULYS LYSPHEGLYALAGLUVAL VAL SERGLYPHEGLNALALEU GGTAAAATTAATAGAGGAGAAGAAATTTGGAGCAGAAGTAGTGTCAGGATTTCAGGCACT SERGLUGLÝCYSLEUPROŤYRAS PILEAŠNGLHMETLEŮASNCYSVALĞLYAS PHISGLN GTCAGAAGGCTGCCTCCCCTATGACATTAATCAGATGTTAAATTGTGTGGGAGACCATCA 1100 ALAALAHETGLNILEILEARGASPILEILEASNGLUGLUALAALAASPTRPASPLEUGLN AGCGGCT ATGCAGATCATCAGAGATATTATA AATGAGGAGGCTGCAGATTGGGACTTGCA 1200 HISPROGLNGLNALAPROGLNGLNGLYGLNLEUARGGLUPROSERGLYSERASPILEALA GCACCCACACAAGCTCCACAACAAGGACAGCTTAGGGAGCCGTCAGGATCAGATATTGC GLYTHRTHRSERTHRVALGLUGLUGLNILEGLNTRPMETTYRARGGLNGLNASHPROILE AGGAACAACTAGTACAGTAGAAGAACAAATCCAGTGGATGTACAGACAACAGAACCCCAT 1300

FIG. 1B-

PROYALGLYASNILETYRARGARGTRPILEGLNLEUGLYLEUGLNLYSCYS YAL ARGNET

ACCAGTAGGCAACATTTACAGGAGATGGATCCAACTGGGGTTGCAAAAATGTGTCAGAAT TYRAS NPROTHRAS NILELEUA SPYALLYS GLNGLYPROLYS GLUPROPHE GLNSERTYR GTATAACCCAACAAACATTCTAGATGTAAAACAAGGGCCAAAAGAGCCATTTCAGAGCTA 1400 VALASPARGPHETYRLYSSERLEUARGALAGLUGLNTHRASPPROALAVALLYSASNTRP METTHRGLNTHRLEULEUILEGLNASNALAASNPROASPCYSLYSLEUVALLEULYSGLY GATGACTCAAACACTGCTGATTCAAAATGCTAACCCAGATTGCAAGCTAGTGCTGAAGGG LEUGLYTHRASNPROTHRLEUGLUGLUMETLEUTHRALACYSGLNGLYVAL GLYGLYPRO GCTGGGTACGAATCCCACCCTAGAAGAAATGCTGACGGCCTGTCAAGGAGTAGGGGGGCC 1600 GLYGUNLYSAL AARGLEUMETAL AGLUALALEULYSGLUALALEUAL APROJLE AGGACAGAAGGCTAGATTAATGGCAGAAGCCCTGAAAGAGGCCCTCGCACCAGCGCCAAT POLYALLEUGLULEUTRP PROPHEAL AAL AAL AGUNG UNLYS GLYPRO ARGLY SPROILELY SCYSTRPASHCYS GLY CCCTTTTGCAGCAGCCCAACAGAAGGGACCAAGAAGCCAATTAAGTGTTGGAATTGTGG 1700 GLUGLYARGTHRLEUCYSLYSALAMETGLNSERPROLYSLYSTHRGLYMETLEUGLUMET LYSGLUGLYHISSERALAARGGLNCYSARGALAPROARGARGGLNGLYCYSTRPLYSCYS GAAGGAAGGACACTCTGCAAGGCAATGCAGAGCCCCAAGAAGACAGOGATGCTGGAAATG TRPLYSASNGLYPROCYSTYRGLYGLNKETPROLYSGLNTHRGLYGLYPHEPHEARGPRO GLYLYSHETASPHIS VALHETALALYSCYS PROASNARGGLNALAGLYPHELEUGLYLEU TRPPROLEUGLYLYSGLUAL APROGLNPHEPROHISGLYSER SERALA SERGLYAL AASP **GLYPROTRPGLYLYSLYSPROARGASNPHEPROMETALAGLNVALHISGLNGLYLEUTHR** TGGCCCTTGGGGAAAGAAGCCCCGCAATTTCCCCATGGCTCAAGTGCATCAGGGGCTGAC 1900 ALAASHCYS SERPROARGARGTHR SERCYSGLY SERALALYS GLULEUHI SALALEUGLY PROTHRALAPROPROGLUGLUPROALAVALASPLEULEULYSASHTYRMETHI SLEUGLY GCCAACTGCTCCCCCAGAAGAACCAGCTGTGGATCTGCTAAAGAACTACATGCACTTGGG GL NA LAAL AGLUARGLYS GL NARGGLUAL AL EUGLNGLYGLY ASPARGGLYPHEAL AAL A LYSGLNGLNARGGLUSERARGGLYLYSPROTYRLYSGLUVALTHRGLUASPLEULEUHIS CAAGCAGCAGAGAAAGCAGAGGGAAGCCTTACAAGGAGGTGACAGAGGATTTGCTGCA Z000 PROGENPHE SERLEUTRPARGARG PROVALVAL THRALAHIS ILEGEUGE YGENPROVAL LEUASNSERLEUPHEGLYGLYASPGLN® CCTCAATTCTCTCTTTGGAGGAGCCAGTAGTCACTGCTCATATTGAAGGACAGCCTGTA GLUVALLEULEUASPTHRGLYALAAS PASP SER ILEVALTHRGLYILEGLULEUGLYPRO GAAGTATTATTAGATACAGGGGCTGATGATTCTATTGTAACAGGAATAGAGTTAGGTCCA HISTYRTHRPROLYSILEVALGLYGLYILEGLYGLYPHEILEASNTHRLYSGLUTYRLYS CATTATACCCCAAAAATAGTAGGAGGAATAGGAGGTTTTATTAATACTAAAGAATACAAA 2200 ASNYAL GLUILEGLUYAL LEUGLYLYSARGILELYSGLYTHRILEHETTHRGLYASPTHR AATGTAGAAATAGAAGTTTTAGGCAAAAGGATTAAAGGGACAATCATGACAGGGGACACC PROTLEAS NI LEPHE GLYAR GASHLEULEUTHRALALEUGLYMETSERLEUASHLEUPRO CCGATTAACATTTTTGGTAGAAATTTACTAACAGCTCTGGGGATGTCTCTAAATCTTCCC 2300 TLEALALYS VALGLUPRO VALLYS SERPROLEULYS PROGLYLYSASPGLYPROLYSLEU ATAGCTAAGGTAGAGCCTGTAAAGTCGCCCTTAAAGCCAGGAAAGGATGGACCAAAATTG LYSGLHTRPPROLEUSERLYSGLULYSILEVALALALEUARGGLUILECYSGLULYSHET AAGCAGTGGCCATTATCAAAAGAAAAGATAGTTGCATTAAGAGAAATCTGTGAAAAGATG (fig.12-suite 1)

GLULYS AS PGLYGLNLEUGLUGLUAL APROPROTHRAS NPROTYRASN THRPROTHRPHE GAAAAAGATGGTCAGTTGGAGGAAGCTCCCCGACCAATCCATATAACACCCCCACATTT 2500 ALAILELY SLYSLYSASPLY SA SNLYSTRPARGMETLEUILE ASPPHEARGGLULEUASN GCT ATAAAGAAAAGGAT AAAAACAAATGGAGAATGCTGATAGATTTTAGGGAACTAAAT ARGYAL THRGL NA SPP HE THRGL UYALGUNL EUGLYILE PROHISPROAL AGLYL EUALA AGGGTCACTCAAGACTTTACGGAAGTCCAAFTAGGAATACCACACCCTGCAGGACTAGCA 26 00 LYSARGLYSARGILETHRVALLEUASPILEGLYASPALATYRPHESERILEPROLEUASP AAAAGGAAAAGGATTACAGTACTGGATATAGGTGACGCATATTTCTCTATACCTCTAGAT 2700 GLUGLUPHEARGGLNTYRTHRALAPHETHRLEUPROSERVALASNASNALAGLUPROGLY GAAGAATTTAGGCAGTACACTGCCTTTACTTTACCATCAGTAAATAATGCAGAGCCAGGA LYSARGTYRILETYRLYSVALLEUPROGLNGLYTRPLYSGLYSERPROALAILEPHEGLN AAACGATACATTTATAAGGTTCTGCCTCAGGGATGGAAGGGGTCACCAGCCATCTTCCAA 28.00 TYRTHRMETARGHISVALLEUGLUPROPHEARGLYSALAASNPROASPVALTHRLEUVAL TACACTATGAGACATGTGCT AGAACCCTTCAGGAAGGCAAATCCAGATGTGACCTTAGTC GLNTYRMETASPASPILELEUILEAL ASERASPARGTHRASPLEUGLUHI SASPARGYAL CAGTATATGGATGACATCTTAATAGCTAGTGACAGGACAGACCTGGAACATGACAGGGTA 2900 VALLEUGL NLEULY SGLULEUL EUA SNSER I LEGLYPHESER SERPROGLUGLULY SPHE GTTTTACAGTTAAAAGAACTCTTAAATAGCATAGGGTTTTCATCCCCAGAAGAGAAATTC 3000 GL NLYSASPPROPROPHEGL NTRPHETGLYTYRGLULEUTRPPROTHRLYSTRPLYSLEU CAAAAAGATCCCCCATTTCAATGGATGGGGTACGAATTGTGGCCGACAAAATGGAAGTTG GL NLYS ILEGLULEUPROGLNARGGLUTHRTRPTHRVALAS NASPILEGLNLYSLEUVAL CAAAAGATAGAGTTGCCACAAAGAGAGACCTGGACAGTGAATGATATACAGAAGTTAGTA 3100 GLYVALLEUASNTRPALAALAGLNILETYRPROGLYILELYSTHRLYSHISLEUCYSARG GGAGTATTAAATTGGGCAGCTCAAATTTATCCAGGTATAAAAACCAAACATCTCTGTAGG LEUILEARGGLYLYSMETTHRLEUTHRGLUGLUVALGLNTRPTHRGLUMETALAGLUALA TTAATTAGAGGAAAAATGACTETAACAGAGGAAGTTCAGTGGACTGAGATGGCAGAAGCA 3200 GLUTYRGLUGLUASNLYS ILEILELEUSERGLNGLUGLNGLUGLYCYSTYRTYRGLNGLU GA AT ATGAGG AAAAT AAAATAATTCT CAGTC AGGAACAAGAAGGATGTTATTACCAAGAA 3300 SERLYSPROLEUGLUALATHRYALILELYSSERGLNASPASHGLNTRPSERTYRLYSILE AGCA AGCC ATTA GA AGCC ACGGT GATA A AGA GTC AGGA CA ATCA GT GG TCTT ATA A A ATT HISGLNGLUASPLYSILELEULYSVALGLYLYSPHEALALYSILELYSASNTHRHISTHR CACCAAGAAGACAAAATACTGAAAGTAGGAAAATTTGCAAAGATAAAGAATACACATACC ASNGLYVALARGLEULEUALAHISVALILEGLNLYSILEGLYLYSGLUALAILEVALILE AATGGAGTTAGACTATTAGCACATGTAATACAGAAAATAGGAAAGGAAGCAATAGTGATC TRPGLYGLNYALPROLYSPHEHISLEUPROVALGLULYSASPVALTRPGLUGLNTRPTRP TGGGGACAGGTCCCAAAATTCCACTTACCAGTTGAGAAGGATGTATGGGAACAGTGGTGG 3500 THRASPTYRTRPGLNYAL THRTRPILE PROGLUTRPASPPHE ILESER THRPROPROLEU ACAGACTATTGGCAGGTAACCTGGATACCGGAATGGGATTTCATCTCAACACCACCATTA 3600 YALARGLEUVALPHEASNLEUVALLYSASPPROILEGLUGLYGLUGLUTHRTYRTYRVAL GTAAGATTAGTETTCAATCTAGTGAAGGACCCTATAGAGGGAGAAGAACCTATTATGTA ASPGLYSERCYS SERLYS GLNSERLYS GLUGLYLYS ALAGLYTYR I LETHRASPARG GLY GAT GGATCAT GTAGTAGA CAGT CAGAAGAAG GAAAAGCAGGATATATCACAGACAGGGGC

(fig. IB-suite 2)

```
3700
 LYSASPLYSVALLYSVALLEUGLUGLNTHRTHRASNGLNGLNALAGLULEUGLUALAPHE
 A A G A C A A G G T A A A G T G T T A G A A C A G C T A C T A A T C A A G C A G A A T T G G A A G C A T T T
 LEUMETALALEUTHRASP SERGLYPROLYSAL AASNILEILEVALASP SERGLNTYRVAL
 CTCATGGCATTGACAGACTCAGGGCCAAAGGCAAATATTATAGTAGACTCACAATATGTT
                3800
 METGLY ILEILETHROLY CYSPROTHROLUSERGLUSE RARGLEUVALAS NOLNILEILE
 GLUGLUMETILELYSLYS THRGLUILETYRVALALATR PVALPROALAHISLYSGLYILE
 GAAGAAATGATCAAAAAGACAGAAATTTATGTGGCATGGGTACCAGCACAAAAGGTATA
 GLYGLYASNGLNGLUILEAS PHI SLEUVAL SERGLNGLYILEARGGLNVALL EUPHELEU
 GGAGGAAACCAAGAATAGACCACCTAGTTAGTCAAGGGATTAGACAAGTTCTCTTCTTG
                                    4000
 GLULYS ILEGLUPROALAGLNGLUGLUH I SSERLYSTYRH I SSERASNILELYSGLULEU
 GAAAAGATAGAGCC AGCACAAGAAGAACATAGTAAATACCATAGTAACATAAAAAGAATTG
 VALPHELYSPHEGLYLEUPROARGLEUVALALALYSGLNILEVALASPTHRCYSASPLYS
 GTATTCAAATTT GGATTACCCAGACTAG TGGCCAAACA GATAGTAGACACATGTGATAAA
               4100
 CYSHISGLNLYSGLYGLUALATLEHISGLYGLNYALASNSERASPLEUGLYTHRTRPGLN
 TGTCATCAAAAAGGAGAAGCTATACATGGGCAGGTAAATTCAGACCTAAGGACTTGGCAA
                                                       4200
METASPCYSTHRHISLEUGLUGLYLYSILEVALILEVALALAVALHIS VALALA SERGLY
ATGGATTGTACCCATCTAGAGGGAAAAATAGTCATAGTTGCAGTACATGTAGCTAGTGGA
PHEILEGLUAL AGLUVAL IL EPROGLING LUTHRGLYAR GGLINTHRALALEUPHELEULEU
4300
LYSLEUALASERARGTRPPROILETHRHISLEUHISTHRASPASHGLYALAASHPHEALA
AAATTGGCAAGCAGATGGCCTATTACACATCTGCACACAGATAATGGTGCTAACTTTGCT
SERGLHGLUVALLYSMETVALALATRPTRPALAGLYILEGLUHISTHRPHEGLYVALPRO
TCGCAAGAAGTAAAGATGGTTGCATGGTGGGCAGGGATAGAGCACACCTTTGGGGTACCA
               4400
TYRASNPROGLNSERGLNGLYVALVALGLUALANETASNHISHISLEULYSASNGLNILE
TACAATCCACAGAGTCAGGGAGTAGTGGAAGCAATGAATCACCACCTGAAAAATCAAATA
                                                       4500
AS PARGILEARGGLUGLNALAASHSERVALGLUTHRILE VALLEUHET ALA VALHISCYS
GATAGAATCAGGGAACAAGCAAATTCAGTAGAAACCATAGTATTAATGGCAGTTCATTGC
RETASHPHELYSARGARGGLYGLY ILEGLYASPHETTHRPROALAGLUARGLEUILEASH
4600
NETILETHRTHRGLUGLNGLUILEGLNPHEGLNGLNSERLYSASHSERLYSPHELYSASH
AT GATCACTACAGAACA AGAAATACAATTTCA ACAATCA AAAAACTCA AAATTTAAAAAT
PHEARGYALTYRTYRARGGLUGLYARGASPGLNLEUTRPLYSGLYPROGLYGLULEULEU
TITCGGGTCTATTACAGAGAAGGCAGAGATCAGCTGTGGAAGGGACCCGGTGAGCTATTG
               4700
TRPLYSGLYGLUGLYALAVALILELEULYSVALGLYTHRASPILELYSVALVALPROARG
TGGAAAGGGGAAGGAGCAGTCATCTTAAAGGTAGGAACAGACATTAAGGTAGTACCCAGG
                                                      4800
ARGLYS ALALYS ILE ILE LY SASPTYRGLYGLYGLYLYS GLUME TASP SER SERSERHIS
                       QMETGLUGLULYSARGTRP ILEVAL VALPROTHR
AGAAAGGCTAAAATTATCAAAGATTATGGAGGAGGAAAAGAGATGGATAGTAGTTCCCAC
METGLUASPTHRGLYGLUAL AARGGLUYALALA
TRPARGILEPROGLUARGLEUGLUARGTRPHIS SERLEUILELYSTYRLEULYSTYRLYS
ATGGAGGATACCGGAGAGGCTAGAGAGGTGGCATAGCCTCATAAAATATTTGAAATATAA
                  (fig.1B-suite 3)
                                4900
```

THREY SASPLEUGENLY SALACYSTYR VALPROHISHISLY SVALCEYTRP ALATRPTRP **AACTAAAGATCTACAAAAGGCTTGCTATGTGCCCCATCATAAGGTCGGATGGGCATGGTG** THRCYSSERARGYAL ILEPHEPROLEUGLNGLUGLYSERHISLEUGLUVALGLNGLYTYR GACCTGCAGCAGAGTAATCTTCCCACTACAGGAAGGAAGCCATTTAGAAGTACAAGGGTA 5000 TRPASMLEUTHRPROGLUARGGLYTRPLEUSERTHRTYRALAYAL ARGILETHRTRPTYR TTGGAATTTGACACCAGAAAGAGGGTGGCTCAGTACTTATGCAGTGAGGATAACCTGGTA SERLY SASPPHETRPTHRASP VALTHRPROGLUTYRAL AASPILELE ULEUHIS SERTHR CT CA AA GGACTITTGGAC AGATGTAACACCAGAATATGCAGATATTTTACTGCATAGCAC TYRPHEPROCYSPHETHRALAGLYGLUVALARGARGALAILEARGGLYGLUARGLEULEU TTATTTCCCTTGCTTTACAGCGGGAGAAGTGAGAAGGGCCATCAGGGGAGAACGACTGCT SERCYSCYSARGPHEPROARGALAHISLYSHISGLNVALPROSERLEUGLNTYRLEUALA GTCTTGCTGCAGGTTCCCAAGAGCTCATAAGCACCAGGTACCAAGTCTACAGTACTTAGC LEUARGVAL VAL SERHI SVAL ARGSERGLINGLYGLUASNPROTHRTRPLYSGLINTRPARG X MET SERASPPROARGGLUARGILEPROPROGLYASNSERGLYGLU ACTGAGAGTAGTAAGTCATGTCAGATCCCAGGGAGAATCCCACCTGGAAACAGTGGAG 5300 ARGASPASHARGARGSERLEUARGVALALALYSGLHASHSERARGGLYASPLYSGLHARG CLUTHRILEGLYGLUALAPHEGLUTRPLEUASNARGTHRVALGLUGLUILEASNARGGLU GLYGLYLYSPROPROTHRGLUGLYALAASHPHEPROGLYLEUALALYSVALLEUGLYILE AL AVALASNHISLEUPROARGGLULEUILEPHEGLNVALTRPGLNARGSERTRPGLUTYR AGGCGGTAAACCACCTACCGAGGGAGCTAATTTTCCAGGTTTGGCAAAGGTCTTGGGAAT TRPHISASPGLUGLNGLYMETSERGLNSERTYRTHRLYSTYRARGTYRLEUCYSLEUILE ACTGGCATGATGAACAAGGGATGTCACAAAGCTATACAAAATACAGATACTTGTGTTTAA 5500 GLNLYSALALEUPHEMETHI SCYSLYSLYSGLYCYSARGCYSLEUGLYGLUGLYHI SGLY TACAAAAGGCTTTATTTATGCATTGCAAGAAAGGCTGTAGATGTCTAGGGGAAGGACACG ALAGLYGLYTRPARGPROGLYPROPROPROPROPROPROGLYLEUALA R METGLU GGGCAGGGGGATGGAGACCAGGACCTCCTCCTCCTCCCCCTCCAGGACTAGCATAAATGG 5600 GLUARGPROPROGLUA SNGLUGLYPROGLNARGGLUPROTRPAS PGLUTRPYAL VALGLU AAGAAAGACCTCCAGAAAATGAAGGCCCACAAAGGGAACCATGGGATGAGTGGGTAGTGG 5700 VALLEULYSGLULEULYSGLUGLUAL ALEULYSHISPHEASPPROARGLEULEUTHRALA AAGTTCTGAAAGAACTGAAAGAAGAAGCTTTAAAGCATTTTGATCCTCGGCTTCTAACCG TAT1 METGLUTHRPROLEUARGGLUGLNGLUASNSER LEUGLYASHHISILETYRASNARGHISGLYASPTHRLEUGLUGLYALAGLYGLULEUILE CACTTGGTAATCATATCTATAATAGACATGGAGACACCCTTGAGGGAGCAGGAGAACTCA 5800 LEUGLUSER SERAS NGLUARG SER SERTYRILE SERGLUALAALAALAALAILE PROGLU ARGILELEUGLNARGALALEUPHEILEHISPHEARGSERGLYCYSSERHISSERARGILE TTAGAATCCTCCAACGAGCGCTCTTCATACATTTCAGAAGCGGCTGCAGCCATTCCAGAA SERALAAS NLEUGLYGLUGLUILELEUS ERGLINLEUTYRARG PROLEUGLUALACYSTYR GLYGLNPROGLYGLYGLYASNPROLEUSERTHRILE PROPRO SERARG SERMETLEU TCGGCCAACCTGGGGGGGGAATCCTCTCTCAACTATACCGCCCTCTAGAAGCATGCTAT 5900 ASHTHRCYSTYRCYSLYSLYSCYSCYSTYRHISCYSGLHPHECYSPHELEULYSLYSGLY AACACATGCTATTGCAAAAAGTGTTGCTACCATTGCCAGTTTTGTTTTCTTAAAAAGGGC LEUGLYILE SERTYRGLULYSSERHISARGARGARGARGTHRPROLYSLYSALALYSALA ARTIMETARGS ERMISTHRGLYGLUGLULEUARGARGARGLEUARGLEU

(fig.lB-suite 4)

TTGGGGATAAGTTATGAGAAGTCACACAGGAGAAGAAGAACTCCGAAGAAGGCTAAGGCT A S NT HR SER SER AL A SER AS NGLU ILEHI SLFULEUMI SGLNTHRSERL YSTYRGL YLEUSERTRPL YSSERALAAL ATYRARG ENV METGLYCYSLEUGLYASHGLNLEULEUILEALA AATACATCTTCTGCATCAAACGAGTAAGTATGGGTTGTCTTGGAAATCAGCTGCTTATCG ILECYS SERLYSCYSLEUTRPILEILECYSILEGUNTYRVALTHRYALPHETYRGLYVAL CCATCTGCTCTAAGTGTCTATGGATTATTTGTATTCAATATGTCACAGTCTTTTATGGTG PROALATRPARGAS NALATHRILE PROLEUPHECY SALATHRLY SASNARGAS PTHRTRP TACCAGCITGGAGGAATGCGACAATTCCCCTCTCTGTGCAACCAAGAATAGGGATACTT 6200 GLYTHRTHRGLNCYSLEUPROASPAS NAS PASPTYRSERGLULEUALALEUASNYALTHR GGGGAACAACTCAGTGCCTACCAGATAATGATGATTATTCAGAATTGGCCCTTAATGTTA 6300 GLUSERPHEASPALAT RPGLUASNTHRVALTHRGLUGLNALAILEGLUASPVALTRPGLN CAGAAAGCTTTGATGCTTGGGAGAATACAGTCACAGAACAGGCAATAGAGGACGTATGGC LEUPHEGLUTHRSERILELY SPROCYS VALLY SLEUSER PROLEUCYS ILETHRHETARG AACTCTTTGAGACCTCAATAAAGCCTTGTGTAAAATTATCCCCATTATGCATTACTATGA CYSASNLYSSERGLUTHRASPLYSTRPGLYLEUTHRLYSSERSERTHRTHRTHRALASER GATGCAATAAAAGTGAGACAGATAAATGGGGATTGACAAAATCATCAACAACAACAGCAT THRTHRTHRTHRTHRTHRALALYS SERVAL GLUTHRARGAS PILE VALAS NGLUTHRŠER CAACAACAACAACAACAACAGCAAAATCAGTAGAGACAAGAGAGACATAGTCAATGAGACTA 6500 PROCYSVALVALHISASPASHCYSTHRGLYLEUGLUGLHGLUPROHETILESERCYSLYS GTCCTTGTGTAGTTCATGATAATTGCACAGGCTTGGAACAAGAGCCAATGATAAGCTGTA PHEASHMETTHRGLYLEULYSARGASPLYSLYSLYSGLUTYRASHGLUTHRTRPTYRSER AATTCAACATGACAGGGTTAAAAAGAGACAAGAAAAGGAGTACAATGAAACTTGGTACT AL AA SPLEUVAL CYSGLUGL NGLYAS NSERTHRGLYAS NGLUSERARGCYST YRMETAS N CTGCAGATCTGGTTTGTGAACAAGGGAATAGCACTGGTAATGAAAGTAGATGTTACATGA 6700 HISCYSASNTHRSERVAL ILEGUNGLUCYSCYSASPLYSASPTYRTRPASPALAILEARG ATCACTGTAATACTTCTGTTATCCAAGAGTGTTGTGACAAAGATTATTGGGATGCTATTA CYSARGTYRCYSALAPROPROGLYTYRALALEULEUARGCYSASNASÖTHRASNTYRSER GATGTAGATATTGTGCACCTCCAGGTTATGCTTTGCTTAGATGTAATGACACAAATTATT GLYPHEMETPROASNCYS SERLYS VALVAL VAL SER SER CYSTHRARGHETMET GLUTHR CAGGCTTTAT GCCTAACTGTTCTAAGGTAGT GGTCTCTTCAT GCACAAGGAT GAT GGAGA GLNTHRSERTHRTRPPHEARGPHEASNGLYTHRARGALAGLUASNARGTHRTYRILETYR
CACAGACTTCTACTTGGTTTCGGTTTAATGGAACTAGAGCAGAAAATAGAACCTATATTT TRPHISGLYARGAS PASHARGTHRILE ILE SERLEUASHLYSHISTYRAS HLEUTHRHET **ACTGGCATGGTAGAGATAATAGGACTATAATTAGTCTAAATAAGCATTATAATCTAACAA** 7000 TGAAATGTAGAAGACCAGGAAATAAGACAGTTTTACCAGTCACCATTATGTCTGCATTGG PHEHIS SERGLNPROVAL AS NGLUARGPROLYSGLNALATRPCYSARGPHEGLYGLYASH TTTTCCACTCACAACCAGTCAATGAGAGGCCAAAGCAGGCATGGTGTAGGTTTGGAGGAA . 71.00
TRPLYSCLUALAIL ELYSCLUVALLYSCLNTHRILE VALLYSHI SPRÖARGTYRTHRÖLY
ATTGGAAGGAGGCAATAAAAGAGGTGAAGCAGACCATTGTCAAACATCCCAGGTATACTG THRASHASHTHRASPLYSTLEASHLEUTHRALAPROARGGLYGLYASPPROGLUVALTHR GAACTAACAATACTGATAAAATCAATTTGACGGCTCCTAGAGGAGGAGATCCGGAAGTTA

(fig.1B-suite 5)

																																								•							•	٠.
				٠.				•	D					. <	N	•	•			c	r.	ı	٧	<b>.</b> I	11	P	HI	F١	F	u	T١	/ R	Ci	'SL	. Y	51	٩E	T.	A S	N	TF	l P	P	н	EL	ΕU	Α	21
	r	•	1 6		١,		ı	•	•		,	"	•	٠,	-	-	1.	•	• -		_	Ξ			_	`-	2	- :	::	Ξ	•						. Ŧ	^		T	10	·	T	T 1	۲r	1 4	Δ	
cc	T	τ	C	. /	١I	1	כ'	Ţ	G(	G,	A (	Ç	4	۱,	ıŢ	Į	G		ı	. A	G	G	A	6	U	1	ı	1	. 1	C	1 /	·	TC				• •	•	~ ^	• •	٠,	, ,	•	•			_	
																										_					7	13	00	)													•	
									•									•			_					•				_	.:	-						-	. 1	ė		٠.		0 /	- 4	S N	T	Y 5
	T	R	٢	٧,	11	ı	L	C۱	LI	IJ	١,	Sí	١,	۱R	G	S	Eŧ	₹	. Е	U	ıT	н	R	۲ŀ	ſR	C	LI	ΝĮ	۲,	>	PH	Ü	LY	> (	,	U	N.K	·	7				~	-	-	-	:	• •
	٠		,	. ,				~	•		- /	. 1	,		ċ	Ā	Ċ	1	٠,			r	T	4	٠,	r	A	c. 1	A	G	c c	٠.	AA	G	: A	A	ĊG	G	CI	١Ţ	A	L A	Α	G	, A	A T	1	
A 1	•	u	•	•	, 1		•	•	•	•	,,	•	•	•••	v	*	•		• •	-	-	٠	•	~`	. •	٠		٠.	-	•	•																_	
																										٠							4							•		_					÷	
							_	_	۰				. 1		•	•	0	- (	-1	N			c	11	F	A	51	N٦	Ìн	₽	TE	P	ΗĪ	Si	. Y	' S 1	٧A	L	GL	. Y	Ł١	r S	A	51	٧V	AL	Ţ	۲,
	•	A			•	•	יט	•	۲.	,,	1		2 1	٠ <u>ـ</u>	. <b>C</b>	-	٠,	•	-		•	:	•	::	: ``	Ξ	•			-	÷								- 1	•				۸,	T C.	11	T	
AC	G	T		10	: 0	: 1	۸	T	C.	1 (	C	١	7	ιŢ	т	A	G	A (	, A	A		1	Α	<b>A</b> 1	C	٨	A	L	ľ	1	11	, 6	C				,	^	v	,,	-	•	_	_	. •	٠.	•	
															7	4	^1	١.								_														•							٠	
									•						•	7	~	٠.		_		_				:						٠.	TI				<b>7</b> L		<b>e</b> 1			: 1	11	1 1	FA	1 4		51
	L	E	L	J P	Ŗ	1	ום	PI	RI	),	١ſ	١,	5 (	31	U	C	Ľ	r,	7.2	P	L	E	υ	Ŧ	١ĸ	C	T	2	12	Ν	3£	: K		, x			4 "	'n	36	-	-		•	Ξ.		= :	-	•
4 T	Ť	7	ċ			• 1	r	٠,	r.	۸,	4 /	2.4	. (	: 4	c	C.	c.	4 (	: 4	C	C	T	C.	4 (	: G	T	C,	T/	LA	c	10	:c	A(	: A	. 1	.C	A C	C	A(	; T	CI	I C	A	1 /	A G	C	A	
~ '	•	•	•	,,	•	•	•	•	•	~ *	~ `	•	•	_		•	٠.	~ `	-	•	•	•	_			٠	-	•		-															7	50	n	
																	4	•								•							•	•						٠								
				٠.		٠.	٠,٠	•		•	r	41		•	D	c		,	. <	N	ıc.	1	N.	Th	4 0	•	FI	0 1	11	F	TH	4 R	ME	7	SE	R	A L	A	G٤	U	V	١L	, Α	L	46	ιι	ľ	E١
	ı	٠				•	٦.	•					•	•	<u>'</u>	ž	=	: :	•	"	ž	።	::	::		7	;:	-	=	Ξ			4			7	• -		r. I	'nc	C 1	1 6	c	c	A C.	44	C	
A C	A	J	A	٨	W	N		Ţ	51		Ŋ,	, 1	ĸ	, ,	ı	G	G	١,	1.0	C	Ļ	4		R (	, :	A	G		١,	Ç.	<b>^</b> \	٠,	AT	0		• • •	,,	. ~	٠,	••	•	•		٠.				
																										_																					٠	
	_		_						•					_		_	. :			_	_		_			J					٠.		11	٠.		10	00	n	11	E	61	٧	'n	٤ı	IΔ		P	RI
	Ţ	Y	R	t A	ŀ	2 (	Ģ١	LI	E١	J	Ξl	Ļ١	JL	. E	u	G	Ľ,	,	12	r	1	T	ĸ.	١ ر	3	L	t١	יט	14	L	υL	.v		. Е	ŗ		<u> </u>	·		::	7.	: :	:	:				•••
T (	7	A	1	r	•		4	7	r	3	: 1	k i	L٦	T	c	G	G.	L C	: 4	T	T	Δ	T.	A٤	A	T	T	A (	it	A	CJ	11	AT	C	١C	ж	CC	A	A٦	IJ	G	; (	, ι	14	. 6	u	·	
	' '	_	•	•	•	•	_	•	• •	•	•	•	•	•	_	•	٠.	•		٠.	•	•••	•	-	• • •	-				•	٠,		^														_	
									•								•	•								•						0	00	,				_		•								
	7		ı	,	•				6 4	1	١	r		P	C	T	Y	2 1	ľH	P	T	н	R	GI	. Y	G	L'	Y 1	ľН	R	SE	R	AF	G	15	N	LY.	'S	A f	łG	GŁ	١.	٧	4	LΡ	HE	٧	Αl
	•	П		•			•	- :			• 1	: :			,	÷				÷		r	•	ř		ř	ž,	ŕ		ř	Ť/	. ,	AC		Ä	T			4 (		60	: 0	c	T	C T	71	G	
CC	. 4	C		١,	./	١	1 (	٠	1 1	. /	4	4 (	ة و	ij	U	1	A(	. 1	. (	. )	٨	L		u (	, 1	v	v	٠,	•	·	• •	,		•	•	•	~ ^	~	۰.,	-~	٠,	•	. •	٠,	٠.	•	-	
																																								•							٠	
		_							٠.							_		٠.	_					Ţ.	, ~	ī			٠,	v			ΑL			T .	c.	٧	۸,				\$	۶	R I	E I	ıT	H
	ι	Ε	ι	JÇ	i	١.	۲ı	PI	41	E١	. (		J	įL	Ţ,	P	H	: L	.Ł	U	A	L	A	1 2	1 ×	A	L	A (	٠.	Ŧ	36	: K	AL	, д	76		<b>9</b> L		~ .		2	: 2	::	2				•••
T C	•	T		'n	: (	: 1		T	T	• 1	r	ľ	:(	: 6	T	Ŧ	T	10	T	C	G	C	A	A(	: G	G	C	A C	; G	T	70	: T	GC	Α.	١ı	G	GG	C	GC	. 6	Gţ	, (	Н	C	6	16	A	
		•	•	•••	•	•	•	•	٠,		٠.			•					•	_	_	_																									_	
								,	•						•	7	01	,								٠							•							•								
	V	A	1	1	•	41	2	8 (	1	l (	:1		1	SE	R	A	R	3 1	ľH	ı	L	Ē	U	L E	U	A	L	4 (	iL	Y	IL	.E	٧,	L	ijι	.N	GL	, N	Gι	۸,	GL	٠,	G	L	A.F	ŁU	L	٤١
	ċ	:		::								.,		7		~	~				Ŧ	Ŧ	•	T 1	c	_	٠,	٧,	ċ	c	À٦	ĪĀ	G1	c		C	٠,	A	٠,	١.	CI	A	C	40	sc	TG	T	
LL	·	•	U	•	•	٠,	٠١			1	. /	• (	,	·	·	Ç	G	,,	·	1	•	٠	_		•	u	·	• •	,,	•	~ '	_	٠.	٠,	-		-	-	•	•	•	•	•					
																										٠														•						60		
		•				٠.			٠.		٠,			ם	_	r			٠,	N	•				: 11		E t	114	0	C		: 11	Th	121	,	1 1	TR	P	Ġı	_ Y	TH	18	L	Y :	S A	SN	IL	E١
	A	3	•	•		•	٠,	•		٠,	• 1		,	.,		v	Ŀ	•		. "	·	٠	•			=	- :	~ :		-	-:		::			Ξ.		ż.					•		- 4	40	-	
TG	G	A	C	: (	1	K	5(	3	П	:/	١,	L(	,,	١G	A	C	A	١c	.Α	A	G	A	A'	71	G	τ	T	GC	. 6	A	Ç I	ı	AC	·C	, ,	L	ı	C	U	, A	*			^'	•	^ `	•	
																										_							_														٠	
				_				•	•						_		. •	٠.		_	_					:			_								٠.		٠.	4		- 11		e i	4 L		Ť	Q F
	G	L	.N	Ħ	'n	11	R	41	R	٦,	"	u	. :	iΕ	R	A	L	ı,	IL	Æ	G	L	U	L٦	7	ı	11	ΚL	.t	U	LI	13	A S	P	·	.N	a L	. А	u		L		•	21	"		1	~'
TĆ	c	•	6	:	ľ	٠,	r a	4	C.	: (	: 1	1	٠1	r	T	G	C	• 4	LT	C	G	•	G.	44	١G	T	A	C 1	T	A	AA	١G	GA	C	: 4	G	GC	G	CJ	١G	ÇŢ	,	IA	V.	rG	CI	1	
	•			•	•••	•		-	•	•	•	' '		•	•	•	•	•	•	_	_	_	_		-	•						•	00														_	
																	•	•								٠														. •			_				•	
	C	•	٩	"	٠,	•	t	4	1	4 5	۱ د	н	5 /	R	C	c	11	u١	18	ı	C	Y	SI	H1	2	T	н	R1	ľH	R	Y A	۱L	PR	ום	R	P	PR	0	A S	SN	AL	_ A	١S	E١	RL	ŧυ	IT	н
	ĭ	:					•	2	-		.:					Ĭ	-		-	=	Ξ	ż	-			ï					-1		~	4				•	4	. T	c	٠,		C.	7	TA		
GG	G	G	1	u	(	•	11	GI	Ç	1		11	1	10	A	C	A /	, (	, 1	C	. 1	Ģ	U	C	·C	A	L	1 1	·	•	6		CC		•		-	•	^,	٠,	٠,	•	_	٠	•	•	_	
																										_														٠							٠	
	_		_				٠.	_ `	•	_							. :	٠.,				_		۰.		ĕ	٠.		- 0	ь.	~1	41	AF			•		•	4		PL	4 6	1	FI	16	11.	IÀ	1 4
	*	K	. (	JA	١:	١,	•	I	K	71	١.	>1	٧,	12	1	b	L	9	ı	ľ	•	ĸ	r	ŀι		U	Ľ	0	K	•	v	٠.			- '	•	::	-	-	"		::	:	=:	-		::	٠.
CA	C	C	1	t	: 1	ľ	1	T	G(	G	L	10	: 1	M	I	G	A	3 /	۱C	1	1	G	G	C١		G	A	GI	ſG	G	GI	١G	C	G	١,	l G	GŦ	T	G١	١C		rc	; 1	Ţ	56	AC	G	
	-	_		-	•	-	•	•	-	•							O		_					-																							_	
								•	•						Ö	v	v	,								٠				_				١						•								٠.
	A	5	٨	()	1	J	Ē'	Ť	H	R	l	Lá	M	.E	U	ıL	E	UC	iL	·	IG	L	V.	AL	. A	G	LI	N)	۱L	E	GL	. N	GL	,N(	۶L	.UI	٧.	2	A :	N	n E	: 1	1	71	K	LV	Ŀ	cl
٠.	٠	ē		i	٠,	ř			_	.,		-	-		r	ŕ	T	ď		ā	ć	Ã	c	cí		r		A	T	Ť	c Ā	A	CA	A	; /	G	44	G	A	NC.	A	10	T	A'	T G	44	T	
		•		•	• •	,	•	•	٠,	٠.	•	- 1	- (		٠	•	• •	•			. •	~	•	- (		•			•	•	•				•					. •		•	٠	•		10		
								,	•								4	•								٠							•	1						•				_	_		_	
	c	ı	ş.	11	٠	•	ς,	1	F	u.	•	51	ď	S F	P	Ť	RI	P /	15	P	٧	4	L	PI	46	C	L	Y	S	N	TA	L P	Pŀ	ŧΕ	15	PI	E	U	T۴	18	SE	ER	l T	RI	ΡĮ	LE	L	Y:
<b>T</b> 4	ž	7	٠,						- `			ï	ř	-			-	,	. ,	÷	ř	7	ï.	۲,	. •	ř	ć,	r	Ā	•	7		TI	7	: 1		CT	T	4	7	T	1	T	G	G A	14	A	
	C	A		• /	. /	11	٠	•		ų,		. 1	, ,	•		. 1	6	, (			v	•	U		•	v	v	.,	•	•	•	, 0	• •	,,			• •	•	- •	• •	• •	•	•	-		•	-	
																																	•														٠	
		·		٠,			- 4	٠,	٠.	u1	٠,			٠.	·			Ē 1					•	T 1	c	v	41		:1	v	v	N I	14	F	5	411	F	Ħ	A E	c	TI	F	v	<b>A1</b>	. 1	LE	T	YI
	•	•	-			٠,	C 1	91	-	4 1		• •	•••	•	• •	•	-	1	•	_		-	=			•		٠,		:	::	•	::		::		-:		7	: :		: :	÷	-		7.		
AG	T	۸	ı	Ľ.	u	1	4(	C	٨	41	r	N	K	; G	A	A	T	F]	r a	1	A	T	A.	A٦	T	G	14	A C	Ģ	A	Ģ١	A	A1	A	. 1	G	1 1	A.	A (	٠,	A I		b	11	•	10	·ŀ	
																																	00							_								
								+	•								. •	•	_			_				•					٠.	"		۱.		_								- 1			ň	•
	I	L	Æ	۲	"	u	.(	d	ĻI	٧I	ч	E	ſι	.E	U	A	u	١,	١ĸ	Ç	iL	ŧ	U	٩ſ	ζG	G	L	N	į	T	"	rĸ	AR	6	ĸ	U	,	L	7	12	26		. 3	C.	ĸr	ņu	ľ	ĸ
A T	•	T	•	10	: 1	1	4	•	۸.	4	1	10	: (	`T		G	C	1	ıc	c	T	T	4	40	: 4	C	1	GC	: G	C.	TA	١T	AC	G	: C	: A	GT	C.	11	31	T	: T	Ŧ	C	CC	Ç A	C	
~ •	-	•	•	•••	, ,	•	•	٠.	~	~	•	' '	,,	•		•	•	•		•	•	٠	_		-	-	'	•	_	_	•	••		•				_	•	•								
									•								•	•								•							•							•	_						٠	
										1	r	1	۲2	4	P	c	PI	Şſ	1	ı	F	P	P	0	5	N	A	R e	i t	L	E 4	R	GL	FL	30	Y	S C	L	NF	R	OL	۲.	3	L١	۲S	٨L	٨	
									4 1	bá	ŗ,	;;				ï		:		=	:	÷		Ξ,	:=	:	~	-:`	÷	-		~		-						ءَ د	Ĺ	Á	٥	c.	LD	cc	1	M
																																	LY															
	•	F	2	7	Y	1	2 1	0	н		3		11			T	H	2 1	13	\$	T	H	R	GI	N	G	L	N A	15	P.	PR	t O	AL	A1	Æ	U	PR	0	11	1R	L١	15	G	L	JG	LY	L	YS
	. =	-	:			:				::					ċ	:	_			:	:	ï		-		ř	7					· -		7		-	-	Ã	٠,	. ,		Á	ć	į,	ı.	cr	A	
LC	. 1	C	. [	Ī		ı l		1	1	Ü	- 1	4(	• 1	d	Ū	A	U	.(	. •	ı	A	U	C	. /		C	Ą١	v (	•	Н	·	. •	GÇ	. 1 (	. 1	v		^	۸,		~′	•	v	~/	••	•	•	
															8	3	01	)								٠														•								
						٠.					٠.			_								v				ž	Ψ.	4,				•	'n		٠.		10		v /	P	c	•	T/	17	1	4.	٠,	ı
LT	٥	Ļ	ı	3	G	ŀ	٠,	,		11	•	•	1	Ų.	L	U	W.	. ,	1	•	. ^	4	<b>#</b>	_,	۱.	•	• •	n)	A		•	ĸ	00		•		••	•		••	-	•	ř	• •	٠,	-1		_
L	Y	S		R	1	:/	M	R	Ġ	1	2 (	; 1	ı	lP	A	R	G	31	.N	ı	R	G	TI	RI	· G	L	N	GL	N,	L	E٤	١L	E٤	IAI	۸.	L	EU	A	١,	۱A	Ş١	•	×	G )	L	t I	T	ĸ
_	ï	ĕ	e			÷	ï		ė	ú			ï	í	v	ċ	ĭ	, ,	c	P	è	í	v	c,	v	ĭ	۲,	N	E	õ	Ć F	: ō	TR	91	) p	n	P	P	C S	N	11	F	C	LI	iΤ	Y P	1	LF
	•		3	•	•	٠,	•	•	•	٠,	•	٠.			. 1	٠	- 1			•	٠.	-	₹'	-		<u></u>	•		-	•		::				~		-	-		::	: :	-	- 1			,	_
	_				c	: 1	l (	i	М	: (	• (	:1	re	G	A	G	GC	: 1	١C	C	G	G	T	66	C	•	A٤	c. 7	١r:	ď,	16	: C	7 0	G	.C	. [ ]	ıG	6		H	Al		L.	A,	٩Œ	a i		
A A	A	A	٠.	•																					_	_	~,	•	•••	v		•						-					_					
A A	A	٨		•			-							_		_	_						•	•		7	_,	•		•		•						_	-	-					à	40	0	
A A	A	A		•			-	,	•					_		•	•								,	•							•		_				•						8	40	0	

SERPHE PROASPPROPROTHRASP THRPROLEUA SPLEUAL AZLEGLNGLNLEUGLNASN HISPHELEUILEARGGUNLEUILEARGLEULEUTHRTRPLEUPHESERASNCYSARGTHR TTCATTTCCTGATCCGCCAACTGATACGCCTCTTGACTTGGCTATTCAGCAACTGCAGAA LEUALA ILEGLUSERILEPROAS PPRO PRO THRAS NI LE PROGLUAL AL EUCYS AS PLFU LEULEUSERARGALATYRGL NILELEUGLNPROILEPHE GLNARGLEUSERALATHRTYR CCTTGCTATCG AGAGCATACCAGATCCTCCAACCAATATTCCAGAGGCTCTCTGCGACCT F METGLYGLYALA ARGARGILEARGARGSERPROGLNALA - ART2 (fin) CLYCLUPHEGLYGLUVALLEUARGLEUGLULEUTHRTYRLEUGLNTYRGLYTRPSERTYR ILE SERLYSLYSARGSERLYSPROPROGLUILECYSASPARGASPSERCYSCLYARGVAL PHEGLNGLUALAVALGLNALAALAARGASPLEUARGGLNARGLEULEUARGALAARGGLY ATTTCCAAGAAGCGGTCCAAGCCGCCAGAGATCTGCGGACAGAGACTCTTGCGGGCGCGTG 8600 GLYARGASHTYRGLYARGLEUPHELYSGLYVALGLUASPGLYSERSERGLNSERLEUGLY GLULYSLEUTRPGLUALALEUGLNARGGLYGLYARGTRPILELEUALATLE PROARGARG GGGAGAAATTATGGGAGGCTCTTCAAAGGGGTGGAAGATGGATCCTCGCAATCCCTAGGA 8700 GLYGGUASPLYSGLYLEUSERSERLEUSERCYSGLUGLYGLNLYSTYRASNGLNGLYGLU ILEARGGLNGLYLEUGLULEUTHRLEULEU • GGATTAGACA AGGGCTT GAGCT CACTCTCTTGTG AGGGCC A AAAATACAATCAGGGAGAA TYRNETASNTHRPROTRPARGASNPROALAGLUGLUARGLYSLYSLEUPROTYRARGLYS TACATGAATACTCCATGGAGAAACCCAGCTGAAGAGAGGAAAAAATTACCATACAGAAAA 8800 GLNASNILEASPASPILEASPGLUGLUASPASPASPLEUVALGLYILEPROVALGLUALA CAAAATATAGATGATAGATGAGGAAGATGATGACTTGGTAGGGATACCAGTTGAGGCC ARGVAL PROLEUARGTHRMET SERTYRLY SLEUALA IL EAS PHET SERHISPHEILELYS AGAGTTCCCCT AAGAACAATGAGTTACAAAT TGGCAATAGATATGTCTCATTTTATAAAA 8900 GLULYSGLYGLYLEUGLUGLYILETYRTYRSERALAARGARGHISARGILELEUASPILE GAAAAGGGGGGACTGGAAGGGATTTATTACAGTGCAAGAAGACATAGAATCTTAGACATA TYRLEUGLULYSGLUGLYILEILEPROASPTRPGLNILEHISSERGLYPROGLYILE TACTTAGAAAAGGAAGAAGGCATCATACCAGATTGGCAGATACACTCCGGACCAGGAATT ARGTYRLEULYS METPHE GLYTRPLEUTRPLY SLEUTLE PROVALAS NYAL SERAS PGLU AGATACCTAAAGATGTTTGGCTGGCTATGGAAATTAATCCCTGTAAATGTATCAGATGAG 9100 ALAGINGLUASPGLUGIUHISTYRLEUVALHISPROALAGINTHRSERGINTRPASPASP GCACAGGAGGATGAGGAGCATTATTTAGTGCACCCAGCTCAAACTTCCCAGTGGGATGAC PROTRPGLYGLUVALLEUAL ATRPLYSPHEASPPROTHRLEUALATYRTHRTYRGLUALA CCTTGGGGAGAGGTTCTAGCATGGAAGTTTGATCCAACTCTAGCCTACACTTATGAGGCA 9200 TYRILEARCTYRPROGLUGLUPHEGLYSERLYSSERGLYLEUSERGLULYSGLUYALLYS TATATTAGATACCCAGAAGAGTTTGGAAGCA AGTCAGGCCTGTCAGAGAAAGAGGTTAAA ARGARGLEUALAALAARGGLYLEULEUGLUHETALAASPARGLYSGLUTHRSER AGAAGGETAGEEGCAAGAGGEETTETTGAAATGGETGACAGGAAGGAAAETAGETGAGAE AGCAGGGACTTTCCACAAGGGGATGTCATGGGGAGGTACTGGGGAGGAGCCGGTTGGGAA CACCCACTTTCTTGATGTATAAATATCACTGCATTTCGCTCTGTATTCAGTCGCTCTGCG GAGAGGETGGEAGATTGAGECETGGGAGGTTETETCEAGEACTAGEAGGTAGAGEETGGG TGTTCCCTGCT AGACTCTCACC AGCACTTGGCCGGTGCTGGGCAGAGTGGCTCC ACGCTT 9600.

(fig.1B-suite 7)

FIG. 1C

séquence LTR CIVET versus H1V-2 ROD

TGGAAGGGATTTATTACAGTGCAAGAAGACATAGAATCTTAGACATATACTTAGAAAAGG TGGAAGGGATGTTTTACAGTGAAAGAAGACATAAAATCTTAAATATATACTTAGAAAAGG AAGAAGGCATCATACCAGATTGGCAGATACACTCCGGA---CCAGGAATTAGATACCTAA AAGAAGGATAATTGCAGATTGGCAGAACTACACTCATGGGCCAGGAGTAAGATACCCAA

FIG. 1C

(fig.1C-suite 1)

# FIG. 2 ( HIV-2.P versus ( HIV-1.P

		• • • • • • • • •	••••••		· ••••••••	
					1	env4
		<del>: •</del>		<del></del>	<del></del>	
	K1 V2		HIII DLLIA	ILLA-SACLY	SETTY VETER	GA5277771
			• • • • • • • • • • • • • • • • • • • •		***	
	HIVIALA	MODERNOSI	RESCUESION	1101111054	TERLEVIVY	GVPVWKEATT
	HIV1	MAKERIVER	Wardanno II.	PROTEITER		***************************************
	• • • • • • • • • •	• • • • • • • • •	• • • • • • • • • • •			• • • • • • • • • •
				•	env5	
		60	70	\$0	env5 yo	100
	Б1 V 2	PLFCATRER-	-DI1/G	TIQCLPDH <u>DD</u>	YOSITL-HVI	EAFDAUNNIV
		***	** *	* * *	** * ***	* * * *
	EIV1	TLFCASDAKA	AMAREASLOA	THACVPIDPN	POEVVLVKVI	ENFRMUKROM
	_				•	
		• • • • • • • • • • •			•••••	
٠.		110	120	env6 130	140	150
)			120	130		
	£1 V2	TEGATITAAR	LP <u>2.1.5 J.K.P.C.V</u>	X.L.I.P.L.C.VA.FIR	Ti:22152210W	KTISKSTSTT
	HIV1	VEQUHEDIIS	LWDQSLKPCV	KLTPLCVSLK	CIDLGE	KTNTHSSNTH
		160	170	130	190	200
	בבבברעזע			PARMICSCICE	TETTUCOENH	
:	EIA5	IIIIIDQE	GETSEBIICK	***	2011110411111	TOPPRINKY
	HIV1	SSSCEMMNER	651X	3621212	121KCKAAKE	INTLIKTOIT
	• • • • • • • • • • •		********		• • • • • • • • •	
				<b>.</b>		1
		210	220	230	env7 240	₩ 250
	HIV2	YNET-WYS	KVVCETHEST	NQTQCYHNHC	nTSVITESCD	KHYHDAIRFR
		* * *		• •	*****	* *
	RIVI	PIDNDTTSYT		TSC	NTSVITOACP	KVSFEPIPIB
	• • • • • • • • • • • • •	• • • • • • • • • •	• • • • • • • • • •	•••••	• • • • • • • • • • •	•••••••
			0			
			env8 270	280		
	BIV2	YCAPPGYALL	RC-NDT-NYS	GFAPNC 5K VV	ASTCTRHMET	QTSTWF-GFW
		**** * * *	* * * *	* * *	**	** *
	RIA1	YCAPAGFAIL	KCNBKTFNGI	GP-CTHVS	TVQCTHGIRP	VVSTQLLL-H
		•				
				-		
		310	320	330	340	350
	EIV2		BTYTYURGED	H-PTTT-SIN	EAAIL CI BUR	PRCHUTUKAT
		* **	* *	* *** **	KAAMT2TKCK	17417141
	D T U 1					
	BIVI	GSLAEEEVVI	ASAMP 1D	WYNTITAGER	42AFTHCI	KEKNHIKKSI
	• • • • • • • • • • • • •	•••••	•••••••	• • • • • • • • •	• • • • • • • • •	• • • • • • • • •
			₽.	0		
		360		env9 380		
:	EIV2	HLHSCHYF	ESHYQPINKR	PROAUCUFEG	-KUKDAHQEV	KETLAKHPRY
			*	***	w#	* *
1	KIV1	RIQROPGRAF				
		• • • • • • • • •	• • • • • • • • • •	• • • • • • • • • •	,	• • • • • • • • • •

	410	J 420	env10	440	450
¥1 U2	RGINDIENIS	FAAPGKGSDP	EVAYEWINGE	GEFLYCKHTE	F18WI
KIV2	* * *	* ***	* **	*** *** *	
HIVI	FGNNKT-II	FKOSS-GGDP	EIVTHSFNCG	GEFFYCKSTQ	LFRSTWFRST
	• • • • • • • • • • • • • • • • • • • •	•			
			• • • • • • • • •	• • • • • • • • • •	
		1		400	500
	460	470	envll 480	970 970	500
EIV2	EN	KTHENYAPCH	IKOIINTWHK	ACKINATUREN	* *
	WSTEGSNNTE	CCNTITIPER	IKOFINHKOE	VGKAHYAPPI	SCOIRCSSHI
HIA1	MOIECONNIE	Capitition	1741 1111142		
		•••			<b>*</b>
	510	520	530	540	550
BIV2	TSIIANIDWQ	KNKQTHITFS	AEVAELYRL-	-ELGDYKLV	EITPIGFAPT
	* *	*** *		** ** *	PICDICULDT
HIV1	TGLLLTRDGG	KNNNGSEIFR	PGGGDHRDNW	KPETIKIKAA	KIEPLUAKEI
• • • • • • • • • • • •	• • • • • • • • •		• • • • • • • • •	•••••	
	env3 560	570	580	590	600
EIV2	RECRYSSANG	RHIRCVFVLG	-FLGFLATA	GSAMGAAS-	LTVSAQSRTL
	* **	* * * *	*****	** *** *	*** * * *
EIV1	KAKRRVVQ.	REKRAVGI-G	ALFLGFLGAA	CSTHGARSHT	LTVQARQL
	• • • • • • • • •	• • • • • • • • • •	• • • • • • • • • •	•••••	• • • • • • • • •
•		420	630	1 640	envl 650
¥ 1 7 2	0000001341	1100000000	1.1.R1.TVVGTK	NLOARVIALE	KYLODOARLN
HIA5	LAGIVQQQQQ	** **	** **** *	***	** ** *
BIV1	LSGIVOOONN	LLRAIEAQQE	LLQLTVWGIK	QLQARILAVE	RYLKDQQLLG
		•	•	•	
	*********		• • • • • • • • •	• • • • • • • • • • • • • • • • • • • •	• • • • • • • • •
	660	670	680	690	700
HIV2	SUCCAFROVE	HIIVPW	VNDSLAPDWD	NATAGEMENT	AKILEWHIZK
HIV1	THECSEKLIC		SKKSLEQIUN		INNYTSLIES
	1				
•	710	env2. 720	730	740	750
BIV2	SLEQAQIQQE	KNMYELOKLN	SUDIFCHUFD	LISHAKAIGA	CATILATAL
WIV!	LIEESQHQQE	*****	**************************************	ITHUIUVIFI	FINT POCT. PC
81V1	Prezavador	vurAerrera	W I W M M M M M M M M M M M M M M M M M	TTHEFT	100210
,					

(fig.2 - suite 1)

	760	770	7 80	. 790	800
HIV2	LRIVIYVVQH	LSRLRKGYRP	V-FSSPPGYI	QQIHIHKDRG	QPANEETEED
	****	* * ** *	*	**	* **
KIV1	LRIVFAVLS1	YKRVRQGYSP	LSFQT-	HLPTPRG	PDRPEGIEEE
					• • • • • • • • • •
	910	820	830	840	850
	810	010			
HIV2	GGSNGGDRYW	PWPIAYIBFL	irqlirlli-	LYSIC	****
			**********	ECVUDI	Philitutpt
HIV1					
					• • • • • • • • • •
	860	870	860	890	900
HIV2	LQLIYQNLRD	WLRLRTA-F	LOYGCEWIQE	AFQ-AAA	RATRETL-
BIV1	VELLGREG	WEALKYWWKL	LQTWSQELKE	SAVSLLNATA	1AVAEGTDR <b>V</b>
• • • • • • • • • • • • • • • • • • • •		••••	••••		
	910	920	930	938	
BIV2	ACACRG	TUPPIFFICE	CTLAUPERIE	OGATIALL	
H147-7		PHUIPPE	****	** * **	
HIAJ	-				

(fig. 2 - suite 2)

FIG.3 ( versus ( ENV-ROD

FIG. 3

HVE DRILTT OKPKERHKRNYVPCHIRGIIN TWHKYGKNYYL PPREGOL TONSTYTSL IAN WIEN-----KT-H-RNYAPCHIKQIINTWHKYGRNYYLPPREGELSCNSTYTSIIAN INHTDGNQTSITMSAEVAELYRLELGDYKLVEITPIGLAPTNVKRYTTG-GTSRNKRGVF IDHONNNOTNITFSAEVAELYRLELGDYKLVEITPIGFAPTKEKRYSSAHG--RHTRGVF VLGFLGFLATAGSAMGAASLTYTAOSRTLLAGIYOOOOOLLDYYKROQELLRLTYWGTKN **VLGFLGFLATAGSAMGAASLTVSAOSRTLLAGIVQQQQQLLDVVKRQQELLRLTVMGTKN** LOTRY SAIE KYLKDOAOLNAHGC AF ROYCHTTYP WP NASLTPOWNNETWOE WERKYDFLE L GARYTA I EKYL ODGARLNSHGCAF ROYCHTTYPHYNDSLAPDWDNHTWOE WEKQYRYLE ANITALLEEAGIGGEKNMYELOKLNSHDYFGNWFDLTSHIKYIGYGIYIIYGYILLRIVI ANISKSLEGAGIGGEKNMYELOKLNSHDIFGNWFDLTSWYKYIQYGVLIIVAVIALRIVI YIVQHLARLRQGYRPVFSSPPSYFQ+THTQQDPALPTKEGKKGDGGGGGGGNSSWPHQIEY YVVOHLSRLRKGYRPVFSSPPGYIQQIHIHKDRGQPANEETEEDGGSNGGDRYWPWPIAY I HFL I RQL I RLL TWLF SNCRTLL SRAY Q I L QP I FOR L SATYGE F G E VLR L E L TYL QY G KS :: : : : ::: IHFLIRGLIRLLTRLYSICRDLLSRSFLTLOLIYONLRDW-----LRLRTAFLQYGCE YFOEAVQAA-RDLRORLLRA-RGEKLHEALORGGRWILAIPRRIROGLELTLL WIQEAFQAAARATRETLAGACRG--LWRVLERIGRGILAYPRRIRQGAEIALL 

(fig. 3-suite 1)

FIG. 4 (GAG-mac (versus (GAG-ROD

**VOHKKEIAYFYPGRDNKIEHEMGARNSVLSGKKADELEKIRLRPGGKKKYMLKHVVWAAN** \*\*\*\*\*\*\* \*\*\*\*\*\* \*\*\*\*\*\*\* \*\*\*\*\*\*\*\*\*\* MGARNSVLRGKKADELERIRLRPGGKKKYRLKHIVHAAN ELDRFGLAESLLENKEGCOKILS YLAPLYPTGS ENLKSLYNTYCY INCIHAEEKYKHTEE KLDRFGLAESLLESKEGCQKILTVLDPHVPTGSENLKSLFNTVCVINCIHAEEKVKDTEG AKOIYORHL VMETGTAETMPKTSRPTAPFSGRGGNYP VOOIGGNYTHLPLSPRTLNAWVK AKQIVRRHL VAETGTAEKMPSTSRPTAPSSEKGGNYP VQHVGGNYTHIPL SPRTLNAWVK LIEEKKFGAEVYSGFQALSEGCLPYDINOMLNCYGDHQAAHQIIRDIINEEAADWDLQHP LYEEKKFGAEYYPGFOALSEGCTPYDINONLNCYGDHQAAMQIIREIINEEAAEWDYQHP QQAPQQ-GQLREPSGSDIAGTTSTVEEQIQHMYRQQNPIPVGNIYRRWIQLGLQKCVRHY \*\*\*\*\*\* \*\*\*\*\*\*\*\*\*\*\* \* \*\*\* \*\*\*\*\*\*\* \* \*\*\*\* I P G P L P A G Q L R E P R G S D I A G T T S T V E E Q I Q W M F R P Q N P V P V G N I Y R W I Q I G L Q K C V R M Y NPTNILDYKQGPKEPFOSYVDRFYKSLRAEQTDPAVKNHMTQTLLIQNANPDCKLVLKGL NPTNILDIK GGPKEPFOSYYDRFYK SLRAEGTDPAVKNYMTGTLLYGNANPDCKLYLKGL GTNPTLEEMLTACQGVGGPGQKARLMAEALKEALAPAPIPFAAAQQKGPRKPIKCHNCGK 1 11111111111111111111111111111111111 GMNPTLEEMLTACQGVGGPGQKARLMAEALKEVIGPAPIPFAAAQQ----RKAFKCHNCGK 

EGHSAROCRAPRROGCHKCGKMDHVMAKCPNROAGFLGLGPWGKKPRNFPMAQVHQGLTP EGHSAROCRAPRROGCHKCGKPGHIMTNCPDROAGFLGLGPHGKKPRNFPVAQVPOGLTP TAPPEEPAVOLLKNYMHLGKOGRES RGKPYKEVTEDLLHL-----NS TAPPYDPAYDLLEKYMOOGKROREORERPYKEVTEDLLHLEQGETPYREPPTEDLLHLNS 500 510 

(fig.4 - suite 1)

FIG.5 (POL-mac (versus (POL-ROD

410 420 430 440	450 460
THE RESERVE OF THE OWNER OF THE VELL METKINK!	OKIELPORETHTYNDIO
	• • • • • • • • • • • • • • • • • • • •
DRVVLQLKELLNGLGFSTPDEKF QKDPPYHMMGYELMPTKWKL	430 440
390 400 410 420	
470 480 490 500	510 520
PLUCUL MULANTY DE LYTYMI COL LPCKATI TEFYOMTE NAEA	EYEENKIILSOEOEGCY
KLYGYLNHAAQLYPGIKTKHLCRLIRGKMTLTEEYOHTELAEA	490 500
450 460 470 480	
530 540 550 560	570 580
VACCUAL CATUTY CODMOUSTY CHOPOKII KYCKFAKIKNIHI	NG YRLL AHY I OK I GKEA
	•• ••••
YGEEKELEATVOKDGENGHTYKIHGEEKILKYGKYAKYKNTHT	550 560
510 520 530 540	
590 600 610 620	630 640
INTHCOMPREHE PARKONHEONHIDANDALMIDENDE IZLAL	VRLVFNLVKDPIEGEET
LAIMOR I DKEHF DAESE I MEONADDA ANGALA I III IIII IIII	*** *** *** * **
LYINGRIPKEHLPVEREINEONAUNYAUVYAUVATATPORDEVSTEEL	610 620
,,,, ,,,, ,,,, ,,,,,,,,,,,,,,,,,,,,,,,	,
650 660 670 680	690 700
YYVDCSCSKOSKECKACYITDRGKDKVKVLEQTTNOQAELEAF.	LWAL TO SEPKANII VUS
FYTDGSCHROSKEGKAGYYTDRGKDKYKKLEGTTHQQAELEAF	AMAI TOSGPKVNI 14DS
630 640 650 660	670 680
0,00 0,00 0,00	
710 720 730 740	750 760
GYVMGIITGCPTESESREVNGIIEEMIKKTELYVANVPAHKGI	11111 1:::::::::
GAAWGIZ V 200 LESE 2K I ANGII EE WI KKE VI ANA A BAHK CI	GGNQEYDHLYSOGIRQY
690 700 710 720	730 740
	810 820
770 780 790 800 LFLEKIEPAGEEHSKYHSNIKELYFKFGLPRLYAKGIYDTCDK	
************* **** *** *** *** *** *	
LFLEK JEPA OE EHEKY HSNYKELSHKFGIPHL VARO I VNSCAD	COOKGEAIHGOVNAELG
750 760 770 780	790 800
830 840 850 860	870 880
THOMDCTHLEGKIVIVAVHVASGFIEAEVIPOETGROTALFLL	KLASRWPITHLHTDNGA
	* * * * * * * * * * * * * * * * * * * *
THOMOCTHLEGKIIIVAVHVASGFIEAEVIPOESGROTALFLL	KLASRYPITHLHIDNGA 850 860
810 820 830 840	9,0 000
890 900 910 920	930 940
NFASQEVKNYANHAGI EHTFGYP YNPOSOGYVEAHNHHLKNOI	DRIREDANSVETIVLMA
11 IIIIIIIII 111 IIIIIIIIIIIIIIIIIIIII	COLDENANTIETIVI MA
870 880 890 900	910 920
950 960 970 980	990
VHCMNFKRRGGIGDMTPAERLINM1TTEGEIGFOOSKNSKFKN	FK4TTREGRUULWKGP6
IHCMNFKRRGGIGOMTPSERLINMITTEGEIGFLGAKNSKLKD	FRYYFREGRDQLWKGPG
930 940 950 960	970 960
1010 1020 1030 -1040	1050 Mentgeareya
ELLHKGEGAVILKYGTDIKYYPRRKAKIIKDYGGGKEMDSSSH	NEUT VERNETA

51

(fig.5-suite 1)

ELLWKGEGAVLVKYGTDIKI IPRRKAKI IRDYGGROEMDSGSHLEGAREDGEMA
990 1000 1010 1020 1030

(fig. 5-suite 2)

FIG.6 (Q.mac (versus (Q.ROD

MEEEKRWIYYPTWRIPERLERWHSLIKYLKYKTKDLQXACYYPHHKYGWAWWTCSRYIFP MEEDKRWIVVPTWRYPGRMEKWHSLYKYLKYKTKDLEKYCYYPHHKYGWAWWTCSRYIFP LOEGSHLEVOGYHNLTPERGWLSTYAVRITWYSKDFWTDVTPEYADILLHSTYFPCFTAG LKGNSHLEIQAYWNLTPEKGWLSSYSYRITWYTEKFWTDYTPDCADVLIHSTYFPCFTAG EVRRAIRGERLLSCCRFPRAHKHOVPSLQYLALRYVSHV-RSQGENPTHKOWRRDNRRSL EVRRAIRGEKLLSCCNYPRAHRAGYPSLGFLALVVVGONDRPGRDSTTRKGRRRDYRRGL RVAKONSRGDKORGGKPPTEGANFPGLAKVLGILA RLAKODSRSHKORSSESPTPRTYFPGVAEVLEILA 

( R.mac FIG.7( versus ( R.ROD

GAGELIRILORALFIHFRSGCSHSRIGOPGGNPLSTIPPSRSML

FIG.8 ( X.mac versus ( X.ROD

MSDPRERIPPGNSGEETIGEAFEWLNRTVEEINREAVNHLPRELIFOVYORSWEYWHDEO MTDPRETYPPGNSGEETIGEAFAWLNRTVEAINREAVNHLPRELIFOVWORSWRYWHDEO GMSQSYTKYRYLCLIQKALFMHEKKGCRCLGEGHGAGGHRPGPPPPPPPGLA GMSESYTKYRYLCIIQKAVYMHVRKGCTCLGRGHGPGGWRPGPPPPPPPGLV 

FIG.9 ( versus ( F.ROD

MGGAISKKRSKPPEICD-RDSCGRYGRNYGRLFK-GYEDGSSOSLGGLDKGLSSLSCEGO MGASGSKKHSRPPRGLOERLLRARAGACGGYWNESGGEYSRFQE--GSDREOKSPSCEGR ã Ò KYNOGEYHNTPWRNPAEERKKLPYRKONIDDIDEEDDDLYGIPYEARYPLRTHSYKLAID QYQQGDFMNTPHKDPAAEREKNLYR QQNMDDVDSDDDDQVRVSVTPKYPLRPHTHRLAID MSHFIKEKGGLEGIYYSARRHRILDIYLEKEEGIIPDWOI-HSGPGIRYLKMFGWLWKL MSHLIKTRGGLEGMFYSERRHKILNIYLEKEEGIIADWQNYTH-GPGVRYPMFFGWLWKL IPYNYSDEAGEDEEHYL VHPAGTSGHDDPHGEVLANKFDPTLAYTYEAYIRYPEEFGSKS :: : : : ::::::::: ::: ::: ::: ::: ::: ::: ::: ::: ::: **YPYDYPOEGEDTETHCLYHPAQTSKFDDPHGETLYWEFDPLLAYSYEAFIRYPEEFGHKS GLSEKEVKRRLAARGLLEMADRKETS** 11 1 1 1 11 111 **GLPEEEWKARLKARGIPFS** 

FIG. 9

FIG.10 ( TAT.mac versus ( TAT.ROD

FIG.11 ( ART.mac versus ART.ROD

KORWRGILALADSIYTFPDPPADSPLDGTIGHLGGLTIGELPDPPTHLPESGRLÆT

80

90

100

70

60

SPQA